

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA
COMPUTAÇÃO**

Alex Sandro da Silva

**DESENVOLVIMENTO DE METODOLOGIAS PARA A DETECÇÃO
AUTOMATIZADA DE PONTOS DE REFERÊNCIA ANATÔMICOS (LANDMARKS)
EM VOLUMES TOMOGRÁFICOS CEREBRAIS HUMANOS**

Dissertação submetida à Universidade Federal de Santa Catarina como parte dos requisitos para a obtenção do grau de Mestre em Ciência da Computação

Prof. Dr. Rer. Nat. Aldo von Wangenheim

Florianópolis, Fevereiro de 2002

AGRADECIMENTOS

Aos meus pais e em especial à minha noiva Cláudia pelo grande apoio, incentivo e compreensão.

Aos colegas e amigos que contribuíram de alguma forma na realização deste trabalho.

Ao meu orientador Aldo pela orientação e apoio para que este trabalho fosse realizado.

Aos professores e servidores da Universidade Federal de Santa Catarina.

SUMÁRIO

RESUMO.....	V
ABSTRACT.....	VI
<u>1 INTRODUÇÃO.....</u>	<u>1</u>
1.1 PROBLEMA.....	1
1.2 JUSTIFICATIVAS.....	2
1.3 OBJETIVO GERAL	3
1.4 OBJETIVOS ESPECÍFICOS.....	3
1.5 ANÁLISE DE REQUISITOS	4
1.5.1 REQUISITOS CONCEITUAIS	4
1.5.2 REQUISITOS DO SISTEMA	5
1.6 ESTRUTURA	5
<u>2 FUNDAMENTAÇÃO TEÓRICA</u>	<u>7</u>
2.1 PROCESSAMENTO DE IMAGENS	7
2.1.1 IMAGENS DIGITAIS.....	8
2.1.2 FORMATO DE IMAGENS	10
2.1.3 TRATAMENTO DE IMAGENS	11
2.1.4 RECONHECIMENTO DE PADRÕES	11
2.2 MORFOLOGIA MATEMÁTICA	13
2.2.1 DEFINIÇÃO DE IMAGEM BINÁRIA	14
2.2.2 DEFINIÇÕES FUNDAMENTAIS	15
2.2.3 DILATAÇÃO E EROÇÃO	15
2.2.4 ABERTURA E FECHAMENTO	22
2.2.5 ESQUELETONIZAÇÃO	24
2.2.6 PROPAGAÇÃO	27
2.2.7 MORFOLOGIA DE IMAGENS EM TONS DE CINZA.....	28
2.3 SEGMENTAÇÃO MUMFORD-SHAH	32
2.3.1 EQUAÇÃO FUNCIONAL DE MUMFORD-SHAH	33
2.3.2 ENERGIA FUNCIONAL SIMPLIFICADA DE MUMFORD-SHAH	35
2.3.3 CRITÉRIO DE JUNÇÃO	36
2.4 NEUROANATOMIA.....	37
2.4.1 DIVISÃO DO ENCEFALO	37
2.4.2 TELENCEFALO	38
2.4.3 DIENCEFALO	44
2.4.4 ROMBECÉFALO OU CÉREBRO POSTERIOR	46
2.4.5 QUARTO VENTRÍCULO.....	47
2.5 ATLAS DE TALAIRACH	49
2.5.1 SISTEMA DE COORDENADAS 3D	49
2.5.2 SEÇÕES DO CÉREBRO.....	51
2.5.3 SISTEMA DE REFERÊNCIA	52

2.5.4 SISTEMA DE GRADES	53
2.6 PLANO HORIZONTAL ALEMÃO	55
2.7 REDES NEURAIS.....	56
2.7.1 NEUROCOMPUTAÇÃO	57
2.7.2 O NEURÔNIO	57
2.7.3 O ELEMENTO DE PROCESSAMENTO	59
2.7.4 ANALOGIA COM O CÉREBRO	60
2.7.5 REDES NEURAIS ARTIFICIAIS	60
2.7.6 TOPOLOGIAS DE REDES NEURAIS ARTIFICIAIS	63
2.7.7 TIPOS DE REDES NEURAIS ARTIFICIAIS	65
2.7.8 MÉTODOS DE CONTROLE DO APRENDIZADO.....	66
2.7.9 MODELOS DE REDES NEURAIS ARTIFICIAIS	69
2.7.10 FASES DE UM PROJETO DE REDES NEURAIS	75
 <u>3 ADAPTAÇÃO AUTOMÁTICA DO ATLAS CEREBRAL.....</u>	 <u>83</u>
3.1.1 METODOLOGIA PARA ADAPTAÇÃO DO ATLAS	83
 <u>4 RESULTADOS E DISCUSSÃO</u>	 <u>103</u>
 <u>5 CONCLUSÃO</u>	 <u>104</u>
 <u>6 BIBLIOGRAFIA.....</u>	 <u>105</u>

RESUMO

Este trabalho apresenta o desenvolvimento de uma ferramenta para adaptar automaticamente um atlas cerebral digital, sendo utilizadas imagens de tomografia computadorizada.

Será utilizado, para servir como base de um sistema de coordenadas ajustado para cada paciente, um plano conhecido como Plano Horizontal Alemão. O Plano Horizontal Alemão é calculado a partir da base do quarto ventrículo, uma estrutura intracerebral de fácil visualização, e os centros de ambos os olhos. Este plano foi escolhido por atender aos requisitos de relacionamento com a biometria do paciente (posicionamento do quarto ventrículo e olhos) e possibilidade de cálculo com base nas imagens tomográficas.

O objetivo é adaptar automaticamente um Atlas Cerebral Digital a qualquer paciente onde foi necessário elaborar uma metodologia de identificação e reconhecimento dessas estruturas intracerebrais (olhos e base do quarto ventrículo).

Palavras-chave: Redes Neurais, Processamento de Imagens, Reconhecimento de Formas, Atlas de Talairach

ABSTRACT

This work presents the development of tool to adaptation automatically of a brain atlas digital, being used images of computed tomography. A coordinates system adjusted for each patient will be used to serve as base, a known plan as German Horizontal Plan. The German Horizontal Plan is calculated from the fourth ventricle base, a brain structure of easy visualization, and the centers of both the eyes. This plan was chosen by support of the requirements of relationship with the biometric position of the patient (positioning of the fourth ventricle and eyes) and possibility of calculation in tomographic images.

The objective is automatically to adapt Brain Atlas Digital to any patient where it was necessary to elaborate a methodology of identification and recognition of these brain structures (eyes and base of the fourth ventricle).

Word-key: Neural Network, Image Processing, Forms Recognition, Talairach Atlas.

1 INTRODUÇÃO

As exigências para modernos sistemas de análise de imagens estão cada vez mais complexas. Isto se torna evidente na área médica, onde imagens de qualidade diferente, com conteúdos bastante diferentes necessitam ser analisadas através do uso de complexos conhecimentos acerca dos elementos esperados. Para atingir o objetivo de reconhecer determinados objetos em imagens, cada imagem é submetida ao processamento por uma seqüência específica de diferentes processos de análise, que vão desde filtros de intensificação de contraste até a classificação de figuras complexas. O processo de reconhecimento de uma imagem consiste, via de regra, de uma composição de filtros, de detectores de bordas, regiões e texturas e de métodos de reconhecimento e classificação de objetos e padrões. A adequação de um determinado método ou processo para a execução de uma determinada tarefa depende fortemente da natureza e dos parâmetros da imagem a ser analisada. Metodologias tradicionais para a análise de imagens com seqüências de operadores e parâmetros fixos, como são utilizadas no controle de qualidade industrial, por exemplo, são aqui inadequadas. Uma metodologia que permita uma adaptação dinâmica e otimizada do processo de extração de características específicas de uma imagem em particular se faz necessária.

1.1 PROBLEMA

O cérebro humano é um órgão onde sua funcionalidade está relacionada com todas as regiões do corpo. Portanto qualquer dano causado em uma região do cérebro deverá comprometer as funções das quais a região afetada é responsável. E uma rápida localização de tais anomalias cerebrais é de fundamental importância tanto para estudos como para diagnósticos.

As técnicas de diagnóstico utilizadas atualmente são tradicionalmente feitas manualmente ou com a ajuda de software oferecido pelo fabricante do equipamento radiológico, que não permitem um diagnóstico confiável e rápido.

Para possibilitar a localização precisa de uma lesão cerebral visível em uma tomografia computadorizada ou ressonância magnética do crânio humano, é necessária a utilização de um sistema especial de coordenadas para a representação das estruturas anatômicas do cérebro e das funções cerebrais a elas associadas. Isto é chamado de Atlas Cerebral Digital, projeto em andamento no contexto do projeto *Cyclops* (LISHA/INE/UFSC).

Atualmente, para a utilização do Atlas, é necessário que o médico faça, manualmente, uma série de ajustes relativos à cabeça específica de cada paciente e ao posicionamento do tomógrafo em relação ao crânio do indivíduo na hora exame. Esta etapa manual de ajuste pode ser eliminada com a determinação de um plano de coordenadas que mantenha relação com a biometria do paciente e que seja calculado a partir das imagens tomográficas.

1.2 JUSTIFICATIVAS

O dia-a-dia da atividade médica é marcado por uma busca constante de um diagnóstico preciso e da avaliação terapêutica, para esse fim o médico serve-se de uma grande variedade de técnicas de produção de imagens, entre eles destacando-se os métodos radiológicos (como por exemplo a Tomografia Computadorizada). Como a interpretação cuidadosa de imagens radiográficas consome tempo, e é caro treinar radiologistas para processar grande número de imagens, o desenvolvimento de um software que auxilie os médicos a diagnosticar com maior agilidade e confiança é de extrema valia.

Percebe-se também que ainda existem muitas necessidades a serem sanadas em diversas áreas quando o assunto é software de auxílio ao diagnóstico médico, mesmo com grandes empresas desenvolvendo soluções nessa área. Dentre estas necessidades, uma

ferramenta que auxilie o médico na localização de áreas cerebrais é uma delas. E ainda não existe uma ferramenta específica para prover esta solução de forma automatizada.

1.3 OBJETIVO GERAL

O objetivo desse trabalho é apresentar uma metodologia para adaptar de forma automatizada um atlas cerebral.

1.4 OBJETIVOS ESPECÍFICOS

1. Desenvolver uma metodologia para a detecção e identificação totalmente automatizada da base do quarto ventrículo e olhos em imagens de tomografia computadorizada do crânio humano, permitindo assim a identificação do Plano Horizontal Alemão;

2. Desenvolver uma metodologia de descrição dessas estruturas encontradas para permitir que os mesmos sejam automaticamente utilizados como pontos de referência (landmarks) para ancorar um atlas cerebral digital deformável;

3. Dado um atlas cerebral digital deformável baseado em um modelo de subvolumes recursivos (octrees anisotrópicas), o Atlas de Talairach, desenvolver uma forma de realizar a adaptação do atlas deformável com base nos landmarks encontrados;

4. Implementar as metodologias acima e demonstrar prototipicamente a sua utilizabilidade através de um conjunto de exemplos de aplicação;

5. Validar as metodologias acima através da realização de um estudo de validação das mesmas em ambiente clínico.

1.5 ANÁLISE DE REQUISITOS

Serão descritos a seguir os requisitos que foram satisfeitos para que os objetivos propostos para este trabalho fossem atingidos.

1.5.1 REQUISITOS CONCEITUAIS

Definir quais estruturas cerebrais serão utilizadas como landmarks para definir a posição do cérebro no volume tomográfico (obj. 1);

Definir e testar um conjunto de métodos de análise de imagens para extrair estas estruturas (obj. 1);

Descrever estes métodos, sua robustez e suas limitações e interdependências entre parâmetros (obj. 1);

Elaborar um conjunto de estatísticas acerca dos parâmetros utilizados para permitir futura automatização do processo (obj. 1);

Definir um conjunto de parâmetros que identifica cada uma das estruturas escolhidas como landmark, descrevendo os segmentos gerados através da segmentação realizada (obj. 2);

Testar métodos para extrair estes parâmetros dos segmentos de imagem obtidos (obj. 2);

Definir metodologia de classificação a ser utilizada para a identificação dos segmentos (obj. 2);

Utilização da informação sobre a posição das estruturas para o posicionamento inicial do Atlas de Talairach (obj. 3);

Definir quais técnicas de descrição espacial serão utilizadas para determinar a posição no espaço (volume tomográfico) das estruturas (obj. 3);

Definir como as bordas do cérebro serão localizadas no espaço. Já que a direção de orientação do atlas será dada pelos landmarks, mas a extensão do atlas pelos limites extremos do cérebro (obj. 2);

Definir uma metodologia de ajuste automático inicial do atlas para que ele se posicione na direção definida pelos landmarks e no tamanho definido pelos pontos extremos definidos pelas extremas do cérebro (obj. 3);

Integração dos métodos desenvolvidos na aplicação Atlas de Talairach (obj. 3);

Teste da aplicação no ambiente clínico do Hospital Universitário da UFSC (obj. 5).

1.5.2 REQUISITOS DO SISTEMA

Desenvolvimento de uma interface automaticamente ajustável aos volumes tomográficos sem interação do usuário.

1.6 ESTRUTURA

A seguir serão descritos brevemente cada capítulo do trabalho.

O capítulo de introdução apresenta uma visão geral deste trabalho, sua importância e objetivos.

O segundo capítulo apresenta uma fundamentação teórica das principais áreas envolvidas, que são: Atlas Cerebral, Neuroanatomia, Processamento de Imagens e Redes Neurais. Neste capítulo são discutidos conceitos, técnicas e ferramentas mais relevantes envolvidas com o tema.

No terceiro capítulo é apresentado o desenvolvimento da trabalho, comentando as técnicas e as ferramentas envolvidas.

No capítulo quatro são discutidos os resultados do presente trabalho.

No quinto capítulo são apresentadas as principais conclusões e sugestões para futuros trabalhos.

2 FUNDAMENTAÇÃO TEÓRICA

A seguir serão apresentados alguns conceitos e técnicas mais relevantes envolvidas com o tema.

2.1 PROCESSAMENTO DE IMAGENS

O processamento de imagens é uma área de estudos da computação que tem evoluído muito nos últimos anos. Seu grande crescimento se deve principalmente ao desenvolvimento de equipamentos, cada vez mais sofisticados e baratos, utilizados para a captura e tratamento de imagens digitais [HAR83].

Muitos problemas práticos podem ser resolvidos com a ajuda de minicomputadores, mais precisamente com máquinas com arquitetura especial. Hardware dedicado, por outro lado, requer algoritmos apropriados para um design com base em componentes de microprocessador padrão [HAR83].

O Processamento Digital de Imagens é um estudo que está inserida dentro do Processamento Gráfico, junto a Computação Gráfica.

A área de Processamento Digital de Imagens teve início em meados da década de 60, com a motivação criada pelos programas espaciais da NASA nos EUA. O aumento da capacidade de memória e velocidade dos computadores contribui para dar impulso à nova tecnologia, que passou a ser aplicada em outras áreas como: medicina, microscopia, ótica eletrônica, transmissão digital de sinais de TV ou fac-símile e em sensores visuais de robôs. Em 1975, a invenção do tomógrafo computadorizado por G. N. Hounsfield, abriu amplas perspectivas de utilização das técnicas digitais de imagens radiográficas [OSO91].

2.1.1 IMAGENS DIGITAIS

O processo de digitalização consiste em realizar a aquisição de uma imagem, a qual é passada para o computador em formato adequado para que este possa manipulá-la. As informações visuais são convertidas em sinais elétricos por sensores óticos, estes sinais são quantificados em valores binários armazenados na memória do computador. No processo de digitalização, os sinais são amostrados espacialmente e quantificados em amplitude, de forma a obter a imagem digital [OSO91].

No processamento de imagens, a imagem digital é definida como sendo uma matriz de $M \times N$ elementos. Cada elemento da imagem digital é denominado de pixel (*picture element*), tendo associado a ele uma informação referente a luminosidade e a cor [OSO91].

Existem vários dispositivos associados às várias aplicações que manipulam imagens. Como exemplo, pode-se citar: o radar, usado na obtenção de imagens de objetos distantes; aparelhos médicos baseados em ultra-som, usados para analisar o interior do corpo humano e a câmara de TV usada na obtenção de imagens locais. Basicamente o processo de formatação das imagens nestes diversos dispositivos é o mesmo [OSO92].

Os digitalizadores de imagens são constituídos basicamente pelos seguintes elementos:

- **ILUMINADOR:** dispositivo responsável pela iluminação do objeto alvo da digitalização;
- **SENSOR:** elemento fotossensível capaz de traduzir uma intensidade luminosa incidente, em valores de corrente elétrica proporcionais a esta luminosidade;
- **CONVERSOR A/D:** o valor contínuo da corrente elétrica gerada pelo sensor é convertido em um valor discreto (analógico \rightarrow digital). Este valor discreto pode então ser armazenado sob a forma numérica na memória de um computador.

Os dispositivos baseados em câmeras de vídeo são capazes de capturar cenas de natureza tridimensional, já o segundo tipo de digitalizadores , os scanners, não possuem a capacidade para adquirir este tipo de imagens. O objetivo alvo da digitalização por um scanner tem que ser plano, podendo ser uma fotografia, impresso ou qualquer outro tipo de objeto plano. Os scanners são muito utilizados na atualidade, podendo ser de três tipos: de mesa, manual ou “*flying spot scanners*” [OSO92].

O resultado do processo de digitalização é a obtenção de uma imagem digital armazenada na memória do computador. Esta imagem pode então ser visualizada ou armazenada em um dispositivo de armazenamento secundário, para posterior processamento.

Existem basicamente dois problemas a serem tratados: a especificação do formato de armazenamento destas imagens e a forma de codificação das mesmas. Estes itens tem que ser analisados cuidadosamente, pois se tomando uma imagem que represente a realidade, esta pode chegar a ocupar 3 Mbytes de memória (1024 x 1024 pixels, com 24 bits/pixel) e neste caso o emprego de algum tipo de técnica de codificação visando a compactação dos dados para o armazenamento, é extremamente aconselhável.

A primeira maneira de armazenar uma imagem é através da gravação linha a linha, coluna a coluna, sem o uso de qualquer tipo de compactação. Neste caso é possível armazenar cada pixel para imagens coloridas. Além da imagem propriamente dita, também terá que ser armazenado o número de linhas e colunas da matriz imagem, de forma que esta possa ser novamente reconstituída. Este sem dúvida não é o melhor método, mais é o mais simples. Um método um pouco mais sofisticado, consiste em realizar a compactação a nível de bytes, ou seja, caso a imagem possua um número de bits/pixel que não seja múltiplo exato do número de bits de um byte, compacta-se a imagem de forma que todos os bits de cada byte sejam utilizados. Nesta técnica, alinham-se as informações a respeito de cada pixel, uma após a outra, sem considerar a organização da memória orientada a bytes, ocupando-se todos os bits [OSO92].

2.1.2 FORMATO DE IMAGENS

Imagens digitais são úteis quando são armazenadas de uma forma que possam ser utilizadas por outras aplicações. Então é necessário colocar estas imagens em uma forma padronizada para que elas possam ser manipuladas por um grande número de aplicações. Programas gráficos podem ser classificados pela forma com a qual armazenam ou apresentam as imagens. Para esta abordagem há duas categorias: formato de varredura e formato vetorial. O formato de varredura é composto por uma série de elementos de imagens, ou pixels, que cobrem uma área apresentada. Imagens de varredura são na maioria das vezes geradas por uma varredura periódica de um feixe de elétrons sobre a superfície de uma imagem que tem um determinado padrão. Os pixels em uma imagem por varredura não são necessariamente relacionados uns aos outros. Também o conceito de forma não é inerente a uma imagem capturada por varredura. Imagens capturadas por varredura são usadas freqüentemente em apresentações gráficas, onde considerações artísticas e qualidade de imagem são importantes [FAC93].

Já o formato vetorial envolve o uso de segmentos de linha orientados ao invés de pixels para representar uma imagem. Uma imagem em formato vetorial é formada por formas geométricas que por sua vez são formadas por segmentos de linha. Conectividade e hierarquia são as principais características de imagens em formato vetorial. Neste formato é fácil verificar quais segmentos de linha fazem parte de um objeto [FAC93].

Existe uma série de especificações de formatos de arquivos utilizados na descrição de imagens. Cada fabricante de um equipamento ou software para aquisição e manipulação de imagens cria um novo formato adequado a sua aplicação.

A solução para este número crescente de formatos diferentes e incompatíveis entre si, é a adoção de um formato padrão e a criação de conversores deste formato para os outros formatos de arquivos (e vice-versa) que possam ser necessários.

Atualmente alguns dos formatos mais utilizados para a descrição e armazenamento de imagens (usados principalmente junto a softwares de desktop publishing) são o BMP, GIF, TIFF, CUT, PCX e NAPLPS [OSO91].

Quando uma imagem vai ser exibida em um dispositivo de saída, este dispositivo pode ou não possuir a capacidade de exibição “imediata” da imagem. Em alguns casos pode ser necessário alterar a resolução espacial da imagem ou a quantificação dos valores de cada pixel, para que então esta possa ser exibida.

2.1.3 TRATAMENTO DE IMAGENS

As imagens digitais podem sofrer algumas modificações, através de um tratamento visando a alteração de suas características, tanto de resolução quanto de quantização. Uma das primeiras técnicas de tratamento de imagens consiste em alterar as características de representação das intensidades luminosas dos seus pontos. As imagens coloridas são consideradas como um caso especial, podendo ser tratadas tomando-se apenas uma escala de intensidades de uma dada cor por vez.

As imagens digitais podem sofrer uma série de operações denominadas operações com filtros. Estas operações realizam tarefas tais como: ressaltar elementos, suavizar ou aumentar o contraste, detectar bordas, remover ruído, etc. Os filtros podem ser implementados para realizar transformações das imagens [OSO91].

2.1.4 RECONHECIMENTO DE PADRÕES

O objetivo de reconhecimento de padrões junto ao processamento de imagens é o de extrair, detectar e identificar elementos presentes em uma cena. Desta maneira, procura-se

imitar o ser humano e suas habilidades, tentando criar dispositivos e algoritmos capazes de realizar as mesmas funções realizadas pelo homem como: localizar objetos, classificar padrões e detectar relações entre estes. A principal vantagem é a de capacitar máquinas a realizarem tarefas até então só possíveis de serem realizadas por seres humanos. As aplicações do reconhecimento de padrões incluem funções como: compactação de dados, aumento da capacidade de aquisição de dados pelo computador, sensoriamento remoto, controle de qualidade, classificação de objetos e uma série de outras aplicações científicas e comerciais.

O reconhecimento de padrões abrange uma gama muito extensa de aplicações e tipos diferentes de objetivos, estando subdivididos em duas principais áreas, de acordo com o tipo de objetivo a ser alcançado: obtenção de descrições (segmentação, vetorização e detecção) e obtenção de classificação (casamento de padrões, identificação de um elemento pertencente a uma classe).

A segmentação da imagem é de grande importância para a análise da imagem. Muitos trabalhos têm sido feitos nesta área. Quando uma figura é segmentada normalmente ocorrem dois problemas [HAR83]:

- Longo tempo computacional e;
- O aperfeiçoamento dos resultados.

O primeiro problema é devido ao grande volume de dados que precisam ser inspecionados e devido a complexidade dos algoritmos “poderosos”, a segunda dificuldade vem do fato que a verificação ótica do homem é sempre subjetiva enquanto o mapeamento do processo de análise da imagem humana para programas eficientes de computador é restrita a alguns aspectos especiais. A diferença essencial entre o reconhecimento do homem e da máquina é o grande conhecimento humano em introduzir a sua análise da imagem [HAR83].

Três estágios do conhecimento podem ser distinguidos: a representação e armazenamento dos dados, o desenvolvimento de programas fazendo uso dos dados e a edição dos conhecimentos dos dados por aprendizado.

Pesquisas convencionais para a análise e reconhecimento de imagens consistem na segmentação da imagem dentro de regiões significativas, extraindo seus limites e sua estrutura, computando variadas figuras e propriedades (ex. perímetro, centro, etc..) e princípios (ex. linha, curva, etc..) e as relações entre as regiões, finalmente, desenvolvendo regras decisivas de descrição, interpretação e / ou classificação da imagem e suas sub-regiões. Num sistema convencional, cada uma destas operações envolve decisões tortuosas (ex. sim ou não, preto ou branco, 0 ou 1) para fazer regiões, figuras, princípios, propriedades, relações e interpretações tortuosas [HAR83].

2.2 MORFOLOGIA MATEMÁTICA

Morfologia é a forma e estrutura de um objeto ou os arranjos e inter-relacionamentos entre as partes de um objeto.

Os mais antigos usos desta palavra estão relacionados com linguagem e biologia. Em lingüística, morfologia é o estudo da estrutura das palavras. Em biologia, morfologia esta relacionada mais diretamente a forma de um organismo. A forma de uma folha pode ser usada para identificar uma planta ou a forma de uma colônia de bactérias pode ser usada para identificar sua variedade.

Morfologia digital é um caminho para descrever ou analisar a forma de um objeto digital.

A morfologia digital é uma ciência relativamente recente, pois só os computadores digitais permitiram seu uso na prática. Por outro lado os matemáticos a consideram uso da teoria de conjuntos que é uma área bem estudada.

A idéia de morfologia digital é que uma imagem consiste de um conjunto de "picture elements" (*pixels*) que são reunidos em grupos tendo uma estrutura bidimensional (forma).

Certas operações matemáticas em conjuntos de pixels podem ser usadas para ressaltar aspectos específicos das formas permitindo que sejam contadas ou reconhecidas.

As operações básicas da morfologia digital são a erosão, em que pixels que não atendem a um dado padrão são apagados da imagem, e dilatação, em que uma pequena área relacionada a um pixel é alterada para um dado padrão. Todavia, dependendo do tipo de imagem sendo processada (preto e branco, tons de cinza ou colorida) a definição destas operações muda, assim cada tipo deve ser considerado separadamente.

2.2.1 DEFINIÇÃO DE IMAGEM BINÁRIA

Uma imagem pode ser definida, de forma alternativa, como um conjunto de coordenadas (x,y) pertencentes a esta imagem, tanto no campo contínuo como no campo discreto. No sentido que este conjunto corresponda aos pontos ou pixels pertencentes ao objeto da imagem. Esta idéia é visualizada na Fig. 1, onde se têm dois objetos ou conjuntos de pixels **A** e **B**. Note a utilização do sistema de coordenadas (n, m) . Neste momento, iremos considerar que os valores que os pixels podem assumir são binários, ou seja, cada pixel ou contém valor 0 ou contém valor 1. Desta forma, podem-se restringir esta análise para o espaço discreto Z^2 .




Figura 1 - Imagem binária contendo 2 objetos

2.2.2 DEFINIÇÕES FUNDAMENTAIS

As operações fundamentais associadas com um objeto são o conjunto padrão de operações: *união* $\{\cup\}$, *interseção* $\{\cap\}$, e *complemento* $\{\complement\}$ com *translação*:

Translação: Dado um vetor \mathbf{x} e um conjunto \mathbf{A} , a *translação*, $\mathbf{A} + \mathbf{x}$, é definida como:

$$\text{Translação: } A + x = \{x + a / a \in A\}$$

Note que, como estamos tratando com imagens digitais compostas de pontos com coordenadas inteiras (\mathbb{Z}^2), isto implica em restrições no vetor de translação \mathbf{x} .

O conjunto básico de operações de *Minkowski* – adição e subtração – podem agora ser definidos, baseado nas considerações anteriores. Dados dois conjuntos \mathbf{A} e \mathbf{B} :

$$\text{Adição de Minkowski: } A \oplus B = \bigcup_{B \in B} (A + B)$$

$$\text{Subtração de Minkowski: } A \ominus B = \bigcap_{B \in B} (A + B)$$

2.2.3 DILATAÇÃO E EROÇÃO

A partir das operações básicas de Minkowski, pode-se definir as operações básicas da morfologia matemática, *dilatação* e *erosão*:

$$\text{Dilatação: } D(A, B) = A \oplus B = \bigcup_{B \in B} (A + B)$$

$$\text{Erosão: } E(A, B) = A \ominus (-B) = \bigcap_{B \in B} (A - B)$$

$$\text{onde } -B = \{-B / B \in B\}$$

Estes dois operações foram aplicadas nos objetos da Fig. 2 e 3.




Figura 2 - a) Dilatação $D(A,B)$




Figura 3 - b) Erosão $E(A,B)$

Tanto o conjunto A como o conjunto B podem ser considerados como sendo uma imagem, entretanto A é usualmente considerado com sendo a imagem a ser analisada e B como o elemento estruturante. O elemento estruturante está para a morfologia como o núcleo de convolução (kernel) está para teoria de filtragem linear.

A dilatação, em geral, faz com que o objeto dilate e cresça no tamanho; enquanto que a *erosão* faz com que o objeto encolha. O modo e a proporção (magnitude) da expansão ou redução da imagem dependem necessariamente do *elemento estruturante* B . Aplicar uma dilatação ou erosão numa imagem sem especificar um elemento estruturante, não causará nenhum efeito nesta. Os dois elementos estruturantes mais comuns (olhando num plano cartesiano) são os conjuntos 4-conexões e 8-conexões, N_4 e N_8 . Conforme Fig. 4 e 5.




Figura 4 - O elemento estruturante padrão N_4




Figura 5 - O elemento estruturante padrão N8

Exemplo de Dilatação:

$$A = \{(1,1), (1,2), (2,1), (2,2)\} = B = \{(0,0), (1,0)\} =$$

Para este caso a equação pode ser reescrita como:

$$A \circ B = [A + \{(0,0)\}] \cup [A + \{(1,0)\}]$$

$$A + \{(0,0)\} = \{(1,1), (1,2), (2,1), (2,2)\} =$$

$$(1,1) + (0,0) = (1,1)$$

$$(1,2) + (0,0) = (1,2)$$

$$(2,1) + (0,0) = (2,1)$$

$$(2,2) + (0,0) = (2,2)$$

A translação de qualquer pixel por (0,0) não altera sua posição.

$$A + \{(1,0)\} = \{(2,1), (2,2), (3,1), (3,2)\} =$$

$$(1,1) + (1,0) = (2,1)$$

$$(1,2) + (1,0) = (2,2)$$

$$(2,1) + (1,0) = (3,1)$$

$$(2,2) + (1,0) = (3,2)$$

$$A \circ B = \{(1,1), (1,2), (2,1), (2,2), (3,1), (3,2)\} =$$

O pixel marcado com um "x" representa a origem (0,0) de cada imagem. A localização da origem é muito importante; No exemplo anterior se a origem do conjunto B fosse o pixel da direita, $\{(-1,0),(0,0)\}$, a dilatação acrescentaria pixels a esquerda na imagem A.

Exemplo de Erosão:

$$A = \{(1,1),(1,2),(2,1),(2,2)\} = B = \{(0,0),(1,0)\} =$$

O conjunto $A \cap B$ é o conjunto de translações de B que alinham B sobre o conjunto de pixels pretos em A. Isso Significa que nem todas as translações necessitam ser consideradas, mas somente aquelas que inicialmente localizam sua origem de B em um membro de A. Existem 4 dessas translações:

$$B_{(1,1)} = \{(1,1),(2,1)\}$$

Como os pixels (1,1) e (2,1) são pretos na imagem A.

O pixel (1,1) no resultado será preto.

$$B_{(1,2)} = \{(1,2),(2,2)\}$$

Como os pixels (1,2) e (2,2) são pretos na imagem A.

O pixel (1,2) no resultado será preto.

$$B_{(2,1)} = \{(2,1),(3,1)\}$$

Como o pixel (3,1) não é pretos na imagem A.

O pixel (2,1) no resultado não será preto.

$$B_{(4,4)} = \{(4,4),(5,4)\}$$

Como o pixel (5,4) não é pretos na imagem A.

O pixel (4,4) no resultado não será preto.

$$A \circ B = \{ (1,1) \mid B_{(1,1)} \cap A \} \cup \{ (1,2) \mid B_{(1,2)} \cap A \}$$

Propriedades da Dilatação e Erosão

A dilatação e a erosão possuem as seguintes propriedades:

Comutatividade: $D(A, B) = A \oplus B = B \oplus A = D(B, A)$

Não-Comutatividade: $E(A, B) \neq E(B, A)$

Associatividade: $A \oplus (B \oplus C) = (A \oplus B) \oplus C$

Invariante de Translação: $A \oplus (B + x) = (A \oplus B) + x$

$$D^C(A, B) = E(A^C, -B)$$

Dualidade: $E^C(A, B) = D(A^C, -B)$

Considerando A como um objeto e A^C como o seu fundo (complemento), esta equação afirma que a dilatação de um objeto é igual a erosão aplicada ao seu fundo. Da mesma maneira, a erosão de um objeto é igual a dilatação aplicada ao seu fundo.

Exceto em casos especiais:

Não-Inversos: $D(E(A, B), B) \neq A \neq E(D(A, B), B)$

A erosão possui a seguinte propriedade de translação:

Invariante de Translação: $A \ominus (B + x) = (A \ominus B) + x$

A dilatação e a erosão possuem a seguinte propriedade importante. Para qualquer elemento estruturante arbitrário B e dois objetos A_1 e A_2 de modo que $A_1 \subset A_2$ (i.e., A_1 é um subconjunto de A_2):

$$D(A_1, B) \subset D(A_2, B)$$

Crescimento em A: $E(A_1, B) \subset E(A_2, B)$

Para 2 elementos estruturantes B_1 e B_2 , de modo que $B_1 \subset B_2$:

Decréscimo em B: $E(A, B_1) \supseteq E(A, B_2)$

O teoremas da decomposição abaixo permitem a implementação de algoritmos eficientes para a filtragem morfológica:

Dilatação: $A \oplus (B \cup C) = (A \oplus B) \cup (A \oplus C) = (B \cup C) \oplus A$

Erosão: $A \ominus x = \{ \alpha \ominus x \mid \alpha \in A \}$

Erosão: $(A \oplus B) \ominus C = A \ominus (B \oplus C)$

Dilatações Múltiplas:
$$\overset{\eta\text{-times}}{B} = (B \oplus \underset{4}{B} \oplus \underset{4}{B} \oplus \underset{4}{B} \oplus \underset{4}{B} \oplus \underset{4}{B} \oplus \underset{4}{B} \oplus \underset{4}{B})$$

Um importante teorema de decomposição é o teorema de Vincent. Primeiramente, precisamos de algumas definições. Um *conjunto convexo* (no R^2) é um conjunto onde qualquer linha reta que ligue quaisquer dois pontos do conjunto, conterà somente pontos pertencentes a este conjunto. Precisamos tomar cuidado ao considerar esta questão no plano discreto, haja visto que o conceito "*linha reta*" precisa ser considerado apropriadamente para o problema em Z^2 . Um conjunto é limitado, se cada um dos seus elementos tem uma magnitude finita, neste caso a distância até a origem no plano de coordenadas. Um conjunto é simétrico, se $B = -B$. Os conjuntos N_4 e N_8 são exemplos de conjuntos convexos, limitados e simétricos.

O teorema de Vicent quando aplicado a uma imagem contendo pixels (pontos) discretos, afirma que para um elemento estruturante limitado, simétrico, que não contém buracos e contém o seu próprio centro, $A^C = \{ \alpha \mid \alpha \notin A \}$.

$$D(A, B) = A \oplus B = A \cup (\partial A \oplus B)$$

onde A é o contorno do objeto. Isto é, A é um conjunto de pixels que possui pelo menos um pixel pertencente ao fundo como seu vizinho.

A implicação deste teorema é que não é necessário processar todos os pontos pertencentes a um objeto para calcular a sua dilatação e/ou a sua erosão, basta processar os pontos pertencentes ao contorno do objeto. Isto também se aplica a todas as operações derivadas da dilatação e da erosão. Isto implica em uma grande redução na complexidade computacional reduzida de $O(N^2)$ para $O(N)$ para uma imagem $N \times N$. Muitos algoritmos velozes podem ser obtidos na literatura que empregam esta técnica. Os mais simples algoritmos de dilatação e erosão são frequentemente descritos da seguinte forma:

Dilatação: Pegue cada pixel binário do objeto (com valor '1') e mude todos os pixels do fundo (com valor '0') que estão C -conectados a este para o valor '1'.

Erosão: Pegue cada pixel binário do objeto (com valor '1') que estão C -conectados aos pixels do fundo (com valor '0') e mude para o valor '0'.

Comparando-se estes dois procedimentos as equações onde $B = N_4$ ou N_8 mostra que estes são equivalentes aos métodos formais da definição da dilatação e erosão. Conforme demonstrado nas Fig. 6 e 7.




Figura 6 - Exemplo de dilatação. Pixels originais em cinza e pixels adicionados em preto($B=N_4$)




Figura 7 - Exemplo de dilatação. Pixels originais em cinza e pixels adicionados em preto($B=N_8$)

2.2.4 ABERTURA E FECHAMENTO

Pode-se ainda combinar a dilatação com a erosão para construir dois operadores mais importantes:

$$\text{Abertura: } O(A, B) = A \circ B = D(E(A, B), B)$$

$$\text{Fechamento: } C(A, B) = A \bullet B = E(D(A, -B), -B)$$

A abertura e o fechamento possuem as seguintes propriedades:

$$\begin{aligned} C^C(A, B) &= O(A^C, B) \\ \text{Dualidade: } O^C(A, B) &= C(A^C, B) \end{aligned}$$

$$\begin{aligned} O(A + x, B) &= O(A, B) + x \\ \text{Translação: } C(A + x, B) &= C(A, B) + x \end{aligned}$$

Para a *abertura* com um elemento estruturante **B** e as imagens **A**, **A₁** e **A₂**, onde **A₁** é uma sub-imagem de **A₂** (**A₁** \hat{I} **A₂**):

$$\text{Antiextensividade: } O(A, B) \subseteq A$$

$$\text{Monotonicidade Crescente: } O(A_1, B) \subseteq O(A_2, B)$$

$$\text{Potência Idêntica: } O(O(A, B), B) = O(A, B)$$

Para o *fechamento* com um elemento estruturante **B** e as imagens **A**, **A₁** e **A₂**, onde **A₁** é uma sub-imagem de **A₂** (**A₁** \hat{I} **A₂**):

$$\text{Extensividade: } A \subseteq C(A, B)$$

$$\text{Monotonicidade Crescente: } C(A_1, B) \subseteq C(A_2, B)$$

$$\text{Potência Idêntica: } C(C(A, B), B) = C(A, B)$$

Exemplos de Abertura

Abaixo, apresenta-se um exemplo básico da técnica de abertura, realizado passo a passo.

$$A \oplus B = A \cup B = (A \cup B) \ominus B =$$

Na Fig. 8 temos um exemplo de abertura utilizando-se como elemento estruturante um disco. A linha pontilhada mais escura apresenta este resultado e na linha pontilhada interna temos o resultado de uma erosão aplicada após a abertura com o mesmo elemento estruturante. Na Fig. 9 apresentamos outro exemplo de abertura com um elemento estruturante específico.




Figura 8 - Exemplo de abertura (linha pontilhada escura) de A




Figura 9 - Abertura de A com o elemento estruturante B

Exemplos de Fechamento

Abaixo, apresenta-se um exemplo básico da técnica de abertura, realizado passo a passo.

$$A = B = A \circ B = (A \circ B) \cap B =$$

Na Fig. 10 temos um exemplo do fechamento de um objeto através de um elemento estruturante na forma de disco. Em linha normal, define-se o objeto apresentado na imagem. Em pontilhado escuro temos o resultado do fechamento realizado. Em pontilhado claro, o resultado da aplicação de uma dilatação em cima do resultado obtido no fechamento.




Figura 10 - Fechamento de A com um elemento estruturante B

2.2.5 ESQUELETONIZAÇÃO

A forma informal de definir esqueletonização é uma linha que representa um objeto com as seguintes propriedades:

- Largura da linha: um pixel;
- Passa pelo "meio" do objeto;
- Preserva a topologia do objeto.

Nem sempre se pode realizar esta operação e atender a todas a propriedades (ver Fig. 11).




Figura 11 - Exemplo onde estas condições não são atendidas

No primeiro exemplo, não podemos gerar uma linha que tenha largura de um pixel e passe pelo centro do objeto. Já no outro exemplo, não podemos esqueletonizar a imagem preservando a sua topologia. Entretanto, existem várias técnicas que auxiliam a obtenção da esqueletonização de objetos, quando isto é possível.

Uma forma básica é baseada no trabalho de Lantuéjoul. O subconjunto *skeleton* $S_k(A)$ é definido como:

$$\text{Subconjuntos Skeleton: } S_k(A) = E(A, kB) - [E(A, kB) \circ B] \rightarrow k = 0, 1, 2, \dots, K$$

onde K é o maior valor de k antes do conjunto $S_k(A)$ se tornar vazio. O elemento estruturante B é escolhido (em Z^2) com uma forma similar a um disco circular, sendo, portanto, convexo, limitado e simétrico. O esqueleto será o resultado da união de um grupo de subconjuntos skeleton:

$$\text{Esqueleto: } S(A) = \bigcup_{k=0}^K S_k(A)$$

Um efeito resultante importante desta análise é que a imagem original pode ser reconstruída fornecendo-se os subconjuntos skeleton $S_k(A)$, o elemento estruturante B , e K :

$$\text{Reconstrução da Imagem: } A = \bigcup_{k=0}^K (S_k(A) \oplus kB)$$

Este método de cálculo do esqueleto da imagem, entretanto, não preserva a sua topologia, não atendendo, portanto, um dos requisitos desejados.

Um método alternativo é implementar um afinador (thinning), uma erosão que reduza um objeto sem perder as suas características morfológicas. Um algoritmo genérico de afinamento é baseado na operação *acerto e erro* (Hit and Miss):

$$\text{Afinador (Thinning): } \text{Thin}(A, B_1, B_2) = A - \text{HitMiss}(A, B_1, B_2)$$

Dependendo da escolha de B_1 e B_2 , uma larga variedade de algoritmos de afinamento podem ser implementadas e, aplicando-se várias vezes estes algoritmos pode-se reduzir uma imagem até o seu esqueleto.

Um método mais prático de afinamento pode ser implementado. Se restringirmos a análise para uma vizinhança de 3x3, similar ao um elemento estruturante $B = N8$ (Ver Fig. 11), então podemos analisar a operação de afinamento como uma janela que repetidamente varre a imagem binária e muda o seu pixel central para '0' sob certas condições. O ponto central da matriz somente não será modificado para '0' se um dos seguintes casos ocorrer:

- um ponto isolado foi encontrado.;
- removendo-se este pixel, estaremos alterando a conectividade da imagem;
- removendo-se este pixel, estaremos reduzindo uma linha.

Como os pixels são (potencialmente) removidos em cada interação, este processo é chamado erosão condicional. Exemplos desta condições estão apresentados na Fig. 12. Em geral, todas as possíveis rotações ou variações destes casos devem ser analisados. Entretanto, como só temos 512 combinações possíveis para uma janela de 3x3 numa imagem binária, isto pode ser feito facilmente através de um estudo de caso.



Figura 12 - Condições de teste: a) Pixel isolado, b) Pixel conectado a outros, c) Pixel no final de uma linha

Se somente a condição 1 for considerada, cada objeto na imagem será reduzido a um único ponto. Isto pode ser útil se desejamos contar o número de objetos em uma imagem. Se somente a condição 2 for usada então detectaremos buracos existentes na imagem. Se as condições 1 e 2 forem usadas, cada objeto será reduzido a ou um único pixel, se o objeto não contém furos, ou a um círculo fechado se este contiver furos. Se as condições 1,2 e 3 forem usadas, então um esqueleto complexo será gerado.

Na Fig. 13 apresenta-se um exemplo do resultado do emprego desta técnica.




Figura 13 - Exemplo de esqueletonização de 3 objetos simples

2.2.6 PROPAGAÇÃO

Em muitos casos é conveniente estar apto a reconstruir imagens que sobreviveram a várias erosões ou se preencher um objeto que está definido apenas pela seu contorno. Os mecanismos formais que fazem isto possuem diferentes nomes como: preenchedor de regiões, reconstrução e propagação. A definição formal é dada pelo seguinte algoritmo. Inicia-se com uma imagem semente $S^{(0)}$, uma máscara A , e um elemento estruturante B . Emprega-se então dilatações de S com o elemento estruturante B e a máscara A , de forma iterativa, como apresentado a seguir:

$$\text{Iteração } k: s^{(k)} = [s^{(k-1)} \oplus B] \cap A \text{ até: } s^{(k)} = s^{(k-1)}$$

A cada iteração a imagem semente irá crescer (através da dilatação) porém sendo limitada pelo conjunto definido por A , i.e. S irá crescer até preencher A . As escolhas mais

comuns para **B** são N_4 e N_8 . Entretanto, o custo de computacional desta operação é extremamente alto, i.e. $O(N^3)$. Felizmente, existe um método iterativo mais eficiente que necessita de somente 2 ou 3 passos, com complexidade N^2 . Conforme demonstrado no Fig. 14.




Figura 14 - A região A é preenchida utilizando-se o elemento estruturante B

2.2.7 MORFOLOGIA DE IMAGENS EM TONS DE CINZA

As técnicas de morfologia matemática podem ser aplicadas também a imagens de tons de cinza. Para simplificar as considerações, será adotado elementos estruturantes **B**, com um número finito de elementos e que são complexos e limitados. Agora, entretanto, o elemento estruturante possui níveis de cinza associado a cada coordenada como uma imagem em tons de cinza normal.

2.2.7.1 DILATAÇÃO EM TONS DE CINZA

Dilatação em Níveis de Cinza:
$$D_G(A, B) = \max_{[j,k] \in B} \{a[m-j, n-k] + b[j, k]\}$$

Para um dada coordenada de saída $[m, n]$, o elemento estruturante é somado com uma versão deslocada da imagem e o máximo valor obtido no domínio $J \times K$ de **B** é usado como

resultado. Deve-se considerar um valor definido para os valores dos pixels fora da imagem, geralmente igual ao valor de fundo da imagem.

A dilatação em imagens de tons de cinza pode ser calculada como:

$$(A \hat{\circ} B) = \max \{A(i-x, j-y) + B(x, y) \mid (i-x, j-y) \hat{\in} A, (x, y) \hat{\in} B\}$$

onde B é um elemento estrutural e A é a imagem de tons de cinza. Para calcular a dilatação faz-se o seguinte:

- posiciona-se a origem do elemento estrutural sobre o primeiro pixel da imagem a ser dilatada;
- calcula-se a soma de cada par correspondente de valores de pixels do elemento estrutural e da imagem;
- acha-se o valor máximo de todas essas somas, e armazena-se o pixel correspondente na imagem de saída para este valor;
- repete-se este processo para cada pixel da imagem a ser dilatada.

Os valores dos pixels do elemento estrutural também são tons de cinza e podem ser negativos. Uma vez que pixel de valores negativos não podem ser mostrados, existem dois possíveis modos de tratar com pixels negativos na imagem resultado:

- valores negativos podem ser alterados para zero (underflow);
- a imagem inteira poderia ter seus valores aumentados para que o menor valor de pixel fosse zero mantendo os valores relativos entre os pixels.

2.2.7.2 EROÇÃO EM TONS DE CINZA

Erosão em Níveis de Cinza: $E_G(A, B) = \min_{[j,k] \in B} \{a[m+j, n+k] - b[j, k]\}$

A Erosão em imagens de tons de cinza pode ser calculada como:

$$(A \hat{\ominus} B) = \min \{A(i-x, j-y) - B(x, y) \mid (i-x, j-y) \hat{\in} A, (x, y) \hat{\in} B\}$$

onde B é um elemento estrutural e A é a imagem de tons de cinza. Para calcular a erosão faz-se o seguinte:

- posiciona-se a origem do elemento estrutural sobre o primeiro pixel da imagem que sofre erosão;
- calcula-se a diferença de cada par correspondente de valores de pixels do elemento estrutural e da imagem;
- acha-se o valor mínimo de todas essas diferenças, e armazena-se o pixel correspondente na imagem de saída para este valor;
- repete-se este processo para cada pixel da imagem que sofre erosão.

2.2.7.3 PROPRIEDADES DA DILATAÇÃO E DA EROÇÃO EM TONS DE CINZA

A dualidade entre a erosão e a dilatação em imagens de tons de cinza são um pouco mais complexa que nas imagens binárias:

$$\text{Dualidade: } E_G(A, B) = -D_G(-\tilde{A}, B)$$

onde ' \tilde{A} ' significa $a[j, k] \rightarrow -a[-j, -k]$.

As definições das operações de nível mais alto como *abertura* e *fechamento* são:

$$\text{Abertura: } O_G(A, B) = D_G(E_G(A, B), B)$$

$$\text{Fechamento: } C_G(A, B) = -O_G(-A, -B)$$

O processo de abertura funciona da mesma forma que definido anteriormente só que usa dilatação e erosão de tons de cinza. Isto é, a abertura usa uma erosão de tons de cinza seguida de uma dilatação de tons de cinza usando o mesmo elemento estrutural.

O processo de fechamento também funciona da mesma forma que definido anteriormente só que usa agora dilatação e erosão de tons de cinza. Isto é, o fechamento usa uma dilatação de tons de cinza seguida de uma erosão de tons de cinza usando o mesmo elemento estrutural.

As propriedades importantes apresentadas anteriormente como potência idêntica, translação, invariância e crescimento em A, também são aplicáveis no caso da morfologia de tons de cinza.

Em muitas situações a complexidade da morfologia de tons de cinza pode ser radicalmente reduzida através da adoção de elementos estruturantes simétricos, onde $b[j,k]=b[-j,-k]$. O mais comum deste caso é baseado no uso de $B = \text{constante} = '0'$. Para este caso especial e considerando novamente o domínio $[j,k] \in B$, as definições acima podem ser reduzidas para:

$$\text{Dilatação: } D_G(A, B) = \max_{[j,k] \in B} \{a[m-j, n-k]\} = \max_B(A)$$

$$\text{Erosão: } E_G(A, B) = \min_{[j,k] \in B} \{a[m-j, n-k]\} = \min_B(A)$$

$$\text{Abertura: } O_G(A, B) = \max_B(\min_B(A))$$

$$\text{Fechamento: } F_G(A, B) = \min_B(\max_B(A))$$

Para uma janela retangular $J \times K$, os filtros bidimensionais de máximo e mínimo podem ser separados em dois filtros unidimensionais. Além disso, um filtro unidimensional pode ser escrito em uma forma incremental. Por causa disto, a dilatação e a erosão em tons de cinza possuem uma complexidade constante $O(\text{constante})$, independente de $J \times K$.

Os operadores apresentados acima podem ser usados para produzir algoritmos morfológicos como suavização, determinação do gradiente e Laplaciano. Todos são obtidos

a partir das primitivas da erosão e dilatação em tons de cinza e no casos dos filtros de máximo e mínimo no domínio $[j, k] \in \mathcal{B}$.

2.3 SEGMENTAÇÃO MUMFORD-SHAH

Este é um método mais preciso para a segmentação, baseado na equação funcional da energia de Mumford-Shah mostrada abaixo:

$$E(u, K) = \iint_{\Omega} \|u - g\|^2 dx dy + \iint_{\Omega / K} \|\nabla u\|^2 dx dy + \lambda * l(K)$$

Abaixo apresentamos uma sequência de imagens na Fig. 15 segmentadas pelo método Mumford-Shah. Na primeira imagem, cada ponto representa uma região. Na primeira segmentação, os pontos vizinhos foram agrupados numa mesma região segundo o critério de menor energia. O valor do nível de cinza dos pontos desta nova região é a média dos pontos agrupados.

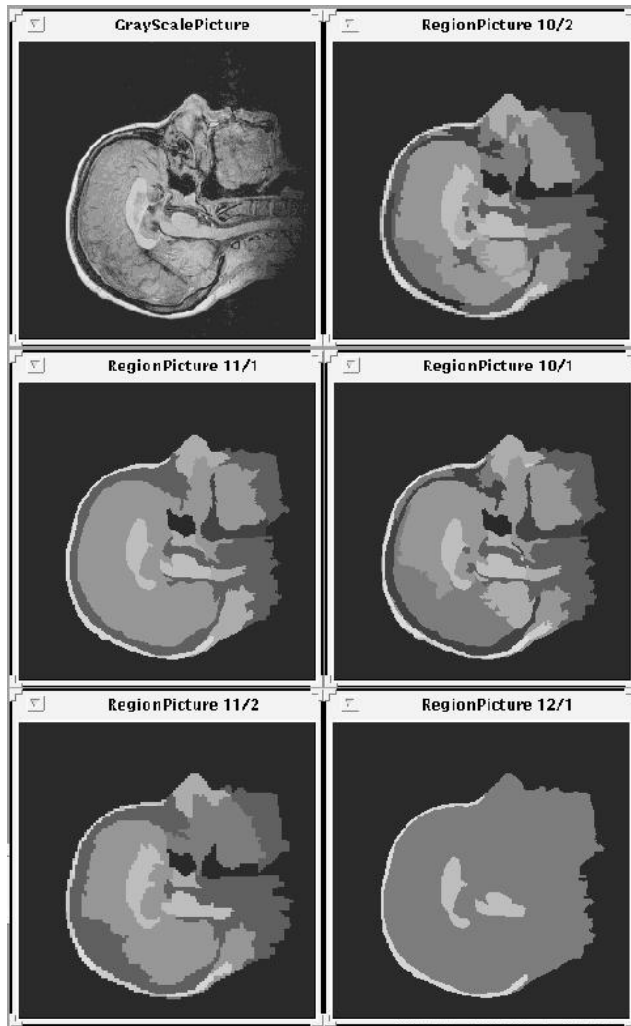


Figura 15 - Sequência de imagens segmentadas pelo método Mumford-Shah

2.3.1 EQUAÇÃO FUNCIONAL DE MUMFORD-SHAH

$$E(u, K) = \iint_{\Omega} \|u - g\|^2 dx dy + \iint_{\Omega / K} \|\nabla u\|^2 dx dy + \lambda * l(K)$$

$E(\square, K)$ - Energia funcional de Mumford-Shah em função de \square e da fronteira K

$g(x, y)$ - função intensidade de luz no ponto x, y .

Ω - Domínio da imagem, geralmente um retângulo.

K - Fronteira entre regiões.

i - Decomposição da imagem em “piece-wise”.

$l(K)$ - comprimento dos arcos das bordas (fronteiras).

(x,y) - função diferenciável dentro de cada região

i - parâmetro de escala

A função $g(x,y)$ é suave (valor de gradiente pequeno) dentro de cada região Ω_i (piece-wise), e é descontínua (valor de gradiente elevado) no cruzamento com as bordas (fronteiras entre regiões). Para o nosso caso, a função $\square(x,y)$ será uma função constante, que é diferenciável dentro da região. E esse valor constante será a média dos valores de intensidade $g(x,y)$ de cada ponto da região.

Segue a interpretação do significado de cada termo da equação funcional da energia de Mumford-Shah:

$$\iint_{\Omega} \|u - g\|^2 dx dy$$

Mede se $\square(x,y)$ é uma boa aproximação de $g(x,y)$.

Quanto melhor a função $\square(x,y)$ se aproximar da função $g(x,y)$, menor será a contribuição desse termo para o valor da energia.

$$\iint_{\Omega/K} \|\nabla u\|^2 dx dy$$

Calcula a variação mínima de (x,y) dentro de cada região sem a borda. No nosso caso como a função $\square(x,y)$ será o valor média dos pontos de $g(x,y)$ dentro da

região e portanto um valor constante, não existirá variação, assim este termo será sempre zero.

$$\lambda * l(K)$$

Calcula o comprimento das fronteiras multiplicado por um parâmetro de escala λ . Quanto maior o comprimento das fronteiras, maior será a contribuição desse termo para o valor da energia. Ainda esse valor será multiplicado por um parâmetro que funciona como um peso.

2.3.2 ENERGIA FUNCIONAL SIMPLIFICADA DE MUMFORD-SHAH

$$E(K) = \iint_{\Omega \setminus K} \|u - g\|^2 dx dy + \lambda * l(K)$$

$g(x,y)$ - Função constante dentro de cada região e é a média dos valores de $g(x,y)$ em cada região. A função da energia simplificada de Mumford-Shah fica em função apenas de K (fronteiras das regiões).

2.3.3 CRITÉRIO DE JUNÇÃO

Dado duas regiões adjacentes O_i e O_j separadas por uma fronteira comum $\square(O_i, O_j)$ e o valor de energia $E(\square, K)$. Uma nova segmentação (\square', K') será obtida, removendo-se a fronteira comum $\square(O_i, O_j)$ dessas duas regiões adjacentes. Esta nova segmentação:

$(\square', K') = (\square, K) \setminus \square(O_i, O_j)$ é agora chamada uma subsegmentação.

Se a energia dessa nova subsegmentação for menor que a energia anterior (antes de juntarmos as duas regiões), ou seja:

$$E(\square', K') < E(\square, K)$$

então, é interessante a junção dessas duas regiões. Porém antes de juntarmos estas duas regiões devemos fazer o mesmo para todas as regiões vizinhas a estas duas regiões O_i e O_j e verificarmos qual é a junção que ocasionará o maior decréscimo de energia.

Caso não se encontre nenhuma região adjacente que ocasione nenhum decréscimo de energia, ou seja:

$$E(\square', K') \geq E(\square, K)$$

então, a segmentação (\square, K) é chamada de 2-normal.

Quando não for mais possível juntar nenhuma região, deve-se aumentar o valor de λ . O incremento de λ poderá ser linear ou exponencial.

2.4 NEUROANATOMIA

Os sistemas neurofuncionais são compostos por redes de neurônios. Responsáveis pela transmissão de sinais, como por exemplo, visuais, auditivos, função motora e suas coordenações.

O cérebro é uma massa compacta, na qual um certo número de estruturas pode ser exibido atualmente por um exame neuroradiológico apropriado. Não podem ser apreciadas outras estruturas neuroanatômicas diretamente, mas só indiretamente por conhecimento da relação de espaço destas estruturas para outras estruturas visíveis.

2.4.1 DIVISÃO DO ENCÉFALO

A. Encéfalo anterior (prosencéfalo):

A.1. Telencéfalo: parte superior do cérebro é dividido em lobos (pré-frontal, parietal, temporal e occipital) ou em números (de acordo com a classificação de Broadmann). A camada superior do telencéfalo é de cor cinza, no entanto seu interior é branco.

B. Encéfalo medial (diencéfalo):

Área de semi consciência, localizada abaixo do telencéfalo, é constituída pelas estruturas: tálamo, hipotálamo, sistema límbico e núcleos ou gânglios da base.

C. Encéfalo posterior (rombecéfalo):

Área totalmente inconsciente do encéfalo, faz a interligação entre a medula espinhal com o diencéfalo. É constituído por duas estruturas tronco cerebral (que se divide em mesencéfalo, ponte e bulbo) e cerebelo. Conforme Fig. 16.




Figura 16 - Corte sagital do encéfalo e medula espinhal. Guyton, A. C. Neurociência Básica, 1993

2.4.2 TELENCEFALO

Com o aumento do tamanho do cérebro na fase evolutiva, a substância cinza expandiu-se desproporcionalmente em relação à substância branca e principalmente à caixa craniana, onde a superfície enrola-se e dobra-se sob si mesma formando os sulcos (o mais importante é o sulco central, que será usada como referências para futuros estudos do encéfalo) e fissuras.

O encéfalo é dividido em dois hemisférios (direito e esquerdo), um parece ser a imagem do outro (conforme Fig. 17). Os hemisférios estão ligados por um feixe espesso de fibras nervosas denominadas de comissuras, a maior denomina-se de corpo caloso, que possibilita que informações de um hemisfério seja passada ao outro e permitindo assim que haja comunicação entre as partes cerebrais.

Área motora Primária: porção imediatamente mais anterior do sulco central, segundo a classificação de Broadmann corresponde ao número 4. Os cientistas Wilder Penfield e Rasmussen, durante cirurgias cerebrais, estimularam o córtex motor primário e descobriram que havia produção de movimentos de todo o corpo. No entanto, algumas áreas possuíam uma representação maior que outras, por exemplo as mãos, lábios, língua e face. Denominaram essa área de mapeamento corporal.

Área pré-motora: porção anterior a área motora primária, correspondendo ao número 6. Está relacionada ao controle de movimentos de fundo e armazenamento de parte do conhecimento para o controle dos movimentos aprendidos.

Área motora suplementar ou campo visual frontal, área 8 da classificação. Esta área localiza-se anteriormente a área pré-motora e está relacionada ao controle de movimentos que exijam contrações bilaterais (braços, olhos principalmente) juntamente com o córtex motor primário, a área pré-motora e a área suplementar também apresentam mapeamento corporal.

Área da Fala ou de Broca: essa área refere-se a produção da fala e controle dos músculos e respiração para a sua execução.

O córtex pré-motor, está situada na porção anterior do encéfalo corresponde a numeração de 44 na classificação de Broadmann. Está envolvida com o comportamento emocional e processos mentais de programação e julgamento.

A.2. Lobo Parietal




Figura 18 - Visão lateral do córtex, nota-se os lobos. Guyton, A. C. Neurociência Básica, 1993

Localizado na porção central do córtex cerebral, uni-se com todos os demais lobos (occipital e temporal) conforme Fig.18 , e sua posição em relação ao sulco central é imediatamente posterior a ele. Na classificação de Brodmann corresponde aos números 1, 2, 3, 5, 7 e 40.

Esta área está relacionada a interpretação de sensações somestésicas tais como: posição do corpo no espaço e sensações provindas destas partes, tato, temperatura e dor. Como toda área sensitiva que será estudada posteriormente, a área somestésica pode ser dividida em duas porções:

- a primeira, imediatamente posterior ao sulco central (numeração de 1,2 e 3) denominada de Área Somestésica Primária e;
- a segunda, posterior a área primária, denominada de área somestésica secundária ou associativa cuja numeração corresponde a 5, 7 e 40. Como ocorre no córtex motores, a área somestésica possui mapeamento corporal com as mesmas

características. No entanto, com função diferente: o mapeamento dessa área é usado para a localização precisa da origem da sensação.




Figura 19 - Divisão do encéfalo em lobos. Observa-se a área de Wernicke. Guyton, A. C. Neurociência Básica, 1993

A.3. Lobo Temporal

Localizado abaixo do lobo parietal, área responsável pela interpretação das sensações auditivas geradas nos ouvidos, corresponde aos números 41 e 42 na classificação de Broadmann. Essa área possui também área primária (41, denominada de Córtex Auditivo Primário) e área secundária ou associativa (42, denominada de Córtex Associativo Auditivo).

A.4. Lobo Occipital

Localizado o mais posterior do sulco central e correspondendo aos números 17, 18 e 19, esta área está relacionada a interpretação de sensações visuais originárias dos olhos. Como as demais, possui área primária denominada de Córtex Visual Primário (17) e área secundária, Córtex Visual Associativo (18 e 19).

A.5. Área Gustativa

Apesar de estarmos citando os lobos e suas áreas sensitivas correspondentes, as áreas olfativas e gustativas não se apresentam localizadas em lobos. A área gustativa está localizada na porção inferior do giro pós-central próxima a parte da área somestésica correspondente à língua. Essa região corresponde ao número 43 da classificação de Broadmann.

Como ocorre com as outras áreas sensitivas, a área gustativa interpreta sensações os sabores ácido, salgado, doce e amargo dos alimentos. Diferentemente das demais áreas citadas anteriormente, não apresenta área secundária.

A.6. Área Olfativa

Porção cortical responsável pela interpretação das sensações olfativas originadas no nariz, localizada na base do córtex cerebral, próxima do diencefalo. Essa área é dividida em duas porções: sistema olfativo medial e sistema olfativo lateral.

A.7. Área de Wernicke

Também denominada de área de interpretação geral, gnóstica, do conhecimento e de associação terciária, localizada entre as áreas somestésicas, auditivas e visuais. Após as percepções serem analisadas em suas respectivas áreas, são enviadas para a área de Wernicke que as associa e gera um significado comum. Outra função importante dessa porção cerebral é o controle da linguagem e relações com as funções da inteligência.

B. Núcleos ou Gânglios da Base

São áreas localizadas na base do córtex cerebral, é um conjunto de núcleos sendo os mais importantes: núcleo caudado, globo pálido e putame (não podendo deixar de citar: claustró e amígdala). Esses núcleos atuam no controle de movimentos, juntamente com as áreas corticais motoras.

2.4.3 DIENCÉFALO




Figura 20 - Visão do Diencéfalo, onde observa-se o tálamo. Guyton, A. C. Neurociência Básica, 1993

Também denominado de cérebro intermediário, localizado abaixo do corpo caloso e acima do mesencéfalo (estrutura componente do tronco cerebral do rombocéfalo). Suas estruturas são: o tálamo, o hipotálamo, o sistema límbico (as principais estruturas), o epitálamo e o subtálamo. Conforme demonstrado na Fig.20.

Tálamo

Órgão par, localizado entre o terceiro ventrículo e córtex cerebral e imediatamente acima do mesencéfalo. Possuindo algumas características importantes:

A.1. formado por inúmeros núcleos distintos;

A.2. devido a sua localização (acima do mesencéfalo), quase todos os sinais sensitivos passam por ele;

A.3. possui inúmeras conexões bidirecionais com as áreas do córtex cerebral.

Devido a essas características importantes, o tálamo atua direcionando os potenciais de ação (principalmente os sensitivos), para os locais específicos do córtex cerebral ou áreas profundas do encéfalo. É capaz de uma identificação grosseira do estímulo e através de suas conexões enviá-lo para áreas específica.

Durante o processo evolutivo encefálico, o córtex cerebral teve origem como um derivado do tálamo. Sendo assim, o tálamo é constituído de áreas correlatas com o córtex, que o possibilita a interpretação grosseira da sensação e o seu direcionamento para áreas específicas corticais.

B. Hipotálamo

Localizado abaixo do tálamo, é formado por um conjunto de núcleos apesar de ser muito pequeno. Seus núcleos controlam o funcionamento interno do corpo, como: a fome, a saciedade, a sede, a temperatura corporal, o metabolismo celular, a concentração de eletrólitos e principalmente todo o sistema endócrino (glândulas e hormônios).

C. Sistema Límbico: localizado nas bordas (daí a origem do seu nome) do diencéfalo, cercando o hipotálamo. Possui várias partes, suas respectivas funções são apresentadas abaixo:

C.1. Amígdala (corpo amigdalóide): localizada próxima ao lobo temporal, acredita-se que atue no controle do comportamento apropriado da pessoa (de acordo com a situação social).

C.2. Hipocampo: em número de dois, localizado na borda do lobo temporal, atua interpretando para o encéfalo a maior parte de nossas experiências sensoriais, e caso seja importante será armazenado, pelo hipocampo na memória no córtex cerebral.

C.3. Corpos Mamilares: localizados atrás do hipotálamo, atua conjuntamente com o tálamo, hipotálamo e tronco cerebral no controle da vigília.

C.4. Septo pelúcido: localizado a frente do tálamo e acima do hipotálamo, controle padrões comportamentais, como por exemplo a ira.

C.5. Giro do cíngulo, o cíngulo, a ínsula e o giro do hipocampo: formam um anel que permite a associação entre as funções corticais cerebrais conscientes e as subconscientes.

2.4.4 ROMBECÉFALO OU CÉREBRO POSTERIOR

É a porção mais inferior do encéfalo, é constituída por duas estruturas distintas: o tronco cerebral e o cerebelo. Essas áreas atuam no controle de funções inconscientes que serão comentadas a seguir.

A. Cerebelo

Localizado abaixo do córtex occipital e atrás do tronco cerebral. Como nas áreas sensitivas somestésicas e áreas motoras, o cerebelo apresenta um mapeamento corporal, com funções diferentes dessas áreas. É constituído pelas seguintes partes:

A.1. Vermis: parte central, possui largura média de 1 a 2 cm e estendendo-se por todo o cerebelo. Aqui, estão representadas as áreas centrais do corpo humano, possibilitando que controle os movimentos relacionados as partes do eixo corporal, do pescoço, dos ombros e quadris.

A.2. Zona Intermediária do hemisfério: localizada entre o vermis e a zona lateral, também é uma faixa estreita. Nessa zona está representada as áreas distais dos membros inferiores e superiores, principalmente as mãos, dedos e face.

A.3. Zona Lateral do hemisfério: localizada lateralmente no cerebelo, é a faixa mais larga. Atua no planejamento geral dos movimentos motores seqüências.

A.4. Lobo Floclunodular: parte mais inferior do cerebelo, relacionado ao controle do equilíbrio.

B. Tronco Cerebral

Localizado abaixo do diencéfalo e acima da medula espinhal, tem a função de conectar o encéfalo à medula espinhal. Sendo a passagem de potencias de ação motores e sensitivos. Constituído pelo mesencéfalo, ponte e bulbo.

B.1. Mesencéfalo: porção mais superior do tronco cerebral, formada por inúmeros componentes que atuam na transmissão de sinais sensitivos e motores, movimentos oculares, e outras.

B.2. Ponte: porção intermediária do tronco cerebral, formada por vários feixes nervosos que transmitem sinais motores e sensitivos, como também de núcleos que controlam: movimentos oculares, expressivos da face, mastigação e sinais sensoriais da face, boca, ouvido e aparelho vestibular.

B.3. Bulbo: porção mais inferior do tronco cerebral, localizado imediatamente acima da medula espinhal. É aqui que as fibras nervosas cruzam para o lado oposto (o hemisfério esquerdo controla o lado direito do corpo e vice-versa). Constituído de feixes nervosos (os mesmos das estruturas anteriores). Possui áreas importantes: sistema nervoso autônomo simpático e parassimpático (controlam função cardiovascular, renal, gastrointestinal e metabolismo) e centro respiratório.

2.4.5 QUARTO VENTRÍCULO

É a cavidade do rombencéfalo, situado entre o bulbo e a ponte ventralmente, e o cerebelo, dorsalmente. Continua caudalmente com o canal central do bulbo e cranialmente com o aqueduto cerebral, cavidade do mesencéfalo, através da qual o IV ventrículo se comunica com o III ventrículo. A cavidade do IV ventrículo se prolonga de cada lado para formar os recessos laterais, situados na superfície dorsal do pedúnculo cerebelar inferior. Estes recessos se comunicam de cada lado com o espaço subaracnóideo por meio das aberturas laterais do IV ventrículo (forames de Luschka). Há também uma abertura mediana do IV ventrículo (forame de Magendie), situado no meio da metade caudal do tecto do ventrículo. Por meio destas cavidades o líquido cérebro-espinhal, que enche a cavidade ventricular, passa para o espaço subaracnóideo.

O assoalho do IV ventrículo, ou fossa rombóide, tem forma losângica e é formado pela parte dorsal da ponte e da porção aberta do bulbo. Limita-se ínfero-lateralmente pelos pedúnculos cerebelares inferiores e pelos tubérculos dos núcleos grácil e cuneiforme. Súpero-lateralmente limita-se pelos pedúnculos cerebelares superiores, ou braços conjuntivos, feixes de fibras nervosas compacto que, saindo de cada hemisfério cerebelar,

fletem-se cranialmente e convergem para penetrar no mesencéfalo. O assoalho do IV ventrículo é percorrido em toda a sua extensão pelo sulco mediano, que se perde cranialmente no aqueduto cerebral e caudalmente no canal central do bulbo. De cada lado do sulco mediano há uma eminência, a eminência medial, limitada lateralmente pelo sulco limitante. Este sulco, separa os núcleos motores, derivados da lâmina basal e situados medialmente, dos núcleos sensitivos, derivados da lâmina alar e situados lateralmente. De cada lado, o sulco limitante se alarga para constituir duas depressões, a fóvea superior e a fóvea inferior, situadas respectivamente nas metades cranial e caudal da fossa rombóide. Medialmente à fóvea superior, a eminência medial dilata-se para constituir de cada lado o colículo facial, formado por fibras do nervo facial, que neste nível contornam o núcleo do nervo abducente. Na parte caudal da eminência medial observa-se, de cada lado, uma pequena área triangular, o trígono do nervo hipoglosso, correspondente ao núcleo do nervo hipoglosso, e lateralmente ao trígono do nervo hipoglosso e caudalmente à fóvea inferior, existe uma outra área triangular, o trígono do nervo vago, que corresponde ao núcleo dorsal do vago. Lateralmente ao sulco limitante e estendendo-se de cada lado em direção aos recessos laterais, há uma grande área triangular, a área vestibular, correspondendo aos núcleos vestibulares do nervo vestibulo-coclear. Cruzando transversalmente a área vestibular para se perderem no sulco mediano, freqüentemente existem finas cordas de fibras nervosas que constituem as estrias medulares do IV ventrículo. Estendendo-se da fóvea superior em direção ao aqueduto cerebral, lateralmente à eminência medial, encontra-se o locus ceruleus, área de coloração ligeiramente escura, cuja função se relaciona com o mecanismo do sono.

A metade cranial do tecto do IV ventrículo é constituída por uma fina lâmina de substância branca, o véu medular superior, que se estende entre os dois pedúnculos cerebelares superiores. Na constituição da metade caudal do tecto tem-se: uma pequena parte da substância branca do nóculo do cerebelo; o véu medular inferior, preso medialmente às bordas laterais do nóculo do cerebelo; tela coróide do IV ventrículo, que une as duas formações anteriores às bordas da metade caudal do assoalho do IV ventrículo. Quando a tela coróide é retirada, suas bordas permanecem como duas linhas, as tênias do IV ventrículo, que se unem sobre o ângulo caudal da cavidade para formar uma pequena lâmina triangular, o óbex. A tela coróide é formada pela união do epitélio endimário, que reveste internamente o ventrículo, com a pia-máter, que reforça externamente este epitélio. A tela

coróide emite projeções irregulares, e muito vascularizadas, que se invaginam na cavidade ventricular para formar o plexo coróide do IV ventrículo, que tem em conjunto a forma de um T, cujo braço vertical é duplo.

2.5 ATLAS DE TALAIRACH

Algumas técnicas de análise e reconstrução de imagens tridimensionais podem não satisfazer as necessidades do usuário, deixando muito a desejar. As imagens, muitas vezes são distorcidas e os resultados gerados podem ser na maioria das vezes, um amontoado de medidas superficiais que não condizem com a realidade. No caso da área de neuroradiologia, um profundo conhecimento do contexto anatômico das imagens torna-se imprescindível, pois a possibilidade de uma representação espacial das estruturas cerebrais facilitaria a visão de lesões ou distúrbios na anatomia.

2.5.1 SISTEMA DE COORDENADAS 3D

As imagens radiológicas têm sido utilizadas principalmente de maneira tradicional, para a descrição verbal e interpretação da lesão. O Atlas de Talairach propõe a interpretação dos espaços cortical e subcortical do cérebro, através da sua representação no espaço. Apresentando dois possíveis modelos para a leitura espacial.




Figura 21 Representação do cérebro em três dimensões

O primeiro modelo de leitura espacial é o método clássico, expresso em milímetros. As medidas são tomadas da linha CA-CP, da VCA vertical e da sagital (Fig. 21).

Por causa da variação no tamanho do cérebro, particularmente em nível de telencéfalo, este método somente é válido com precisão, somente para os cérebros com tamanhos inferiores ao utilizado como piloto.

O segundo método introduz o conceito de proporcionalidade, e é baseado em um sistema de grade ortogonal derivado da linha CA-CP (Anterior Commissure – Posterior Commissure). As dimensões do sistema de grades podem se alterar de acordo com as dimensões do maior osso de um determinado cérebro.

Este sistema de localização permite o mapeamento de todo espaço cortical e subcortical. Desta forma, é possível identificar, em três dimensões, as principais estruturas contidas nestas áreas.

Para a aplicação desta ferramenta realiza-se uma série de secções anatômicas nos planos frontal, horizontal e sagital do cérebro. Estas secções emparelhadas plano a plano

facilitam a percepção espacial do volume cerebral. As linhas basais formam um frame de referência definindo a orientação e posição espacial das estruturas na massa cerebral.

Este frame é a chave para a passagem de um plano para o outro, permitindo que se tenha maior precisão na transição de uma imagem radiológica para uma secção anatômica correspondente, e inversamente para localizar na imagem radiológica a estrutura anatômica que ficou escondida. A grade proporcional feita por este Atlas, deriva de um cérebro particular e é aplicada a qualquer outro cérebro posteriormente examinado. Isto é altamente relevante para estudos clínicos (radiológicos, neurológicos, neurocirúrgicos e neurofisiológicos).

O desenho da secção sagital resulta em traços fotográficos em dimensões reais de secções anatômicas apresentadas de forma diferente das condições anteriormente apresentadas nas tomografias.

Detalhes irrelevantes das imagens são deixados de fora. Desta forma para manter uma certa clareza nas secções, os números de estruturas anatômicas presentes e selecionadas são aquelas que apresentam maior importância atualmente.

2.5.2 SEÇÕES DO CÉREBRO

Na verdade, Talairach criou um sistema de grades proporcional com uma metodologia para uma razoável montagem e comparação de estudos sucessivos de pacientes com hemisférios cerebrais com tamanhos e proporções individuais, possibilitando a criação de um banco de dados preciso para a localização de estruturas cerebrais no espaço tridimensional (Fig. 22).




Figura 22 - Seções mapeadas do cérebro

2.5.3 SISTEMA DE REFERÊNCIA

Três linhas de referência servem de base para este sistema de grades proporcional e tridimensional, são elas: CA-CP, VCA e sagital:

2.5.3.1 LINHA BASAL CA-CP

Esta linha passa através da borda superior da comisura anterior e a borda inferior da comisura posterior. Seguindo o caminho paralelo ao sulco do hipotálamo e separando a região do tálamo da região do subtálamo.

Esta linha define o plano horizontal. A linha basal VCA é uma linha transversal vertical na margem posterior da comisura anterior. Esta linha é a base para o plano vertico-frontal. A linha basal sagital é a linha inter-hemisférica que define o plano sagital.



Figura 23 - Sulcos principais que determinam as linhas VCA, VCP e Sagital

2.5.4 SISTEMA DE GRADES

A distância entre os planos pode ser medida em milímetros. Porque as variações em altura, largura e comprimento varia de um cérebro para outro. Isto se torna cada vez mais verdadeiro quando se têm grandes distâncias entre as linhas basais. Medidas milimétricas para o núcleo central acinzentado, de fato, são somente aplicáveis em uma população genérica cujas variações dimensionais permanecem moderadas.

O sistema de grade proporcional e tridimensional é estabelecido de acordo com as dimensões máximas do cérebro nos planos do espaço tridimensional. Este sistema adapta-se a todas as dimensões do cérebro, e é igualmente eficiente para imagens radiológicas de todas as dimensões. Este sistema de localização proporcional delimita as distâncias de separação das linhas basais e a periferia cortical definida pelas linhas através dos:

- ponto limite superior do córtex parietal;
- ponto limite posterior do córtex occipital;
- ponto limite inferior do córtex temporal;
- ponto limite anterior do córtex frontal;
- ponto limite lateral do córtex parietotemporal.




Figura 24 - Linhas principais (VCA,VCP, CA-CP)

O modelo definido por Talairach especifica que a cima da linha CA-CP, o cérebro deverá ser dividido em oito partes, e a baixo dela, o cérebro ficará dividido em quatro partes.

Por linhas verticais anteriores a linha VCA, divide-se o cérebro em quatro partes, posterior a linha VCP, divide o cérebro também em quatro partes.

A parte do cérebro é dividida em paralelogramos ortogonal, a dimensões de cada paralelogramo variam de acordo com os principais eixos do cérebro. Cada um destes volumes é definido por suas três dimensões.

O espaço entre as duas linhas perpendiculares através das comissuras anteriores e posterior é dividido individualmente em três zonas, pois isto garante uma maior precisão na localização do núcleo central acinzentado e define compativelmente a localização do córtex motor. O sistema de grade proporcional, após a localização das estruturas corticais e subcorticais com relativa precisão, demarca todos os três planos do espaço seja qual for a forma e o tamanho do cérebro.

Usando este sistema proporcional, isto é, baseando as divisões do cérebro em proporções de cérebros individuais pode-se realizar estudos estatísticos, porque cada caso individual pode ser reduzido à escala comum (Fig. 25).




Figura 25 - Divisão do cérebro em paralelogramos ortogonais

Os retângulos da grade são desenhados em três planos do espaço para dividir a massa do cérebro em vários paralelogramos retangulares, os quais correspondem na direção vertical em doze setores horizontais. Na direção antero-posterior por nove setores verticofrontais, sendo identificados de “A” até “T”, na direção transversal é dividido em 4 secções, designadas de “a” até “d”.

Para evitar a criação de volumes que não possam ser usados genericamente, os setores são divididos em setores intermediários. Para as secções sagitais, os setores intermediários não podem exceder 4mm de cada um dos lados da linha divisória;

Estas divisões do cérebro em volumes unitárias são o caminho para um Atlas computadorizado. Tais atlas podem destacar cada uma de todas as estruturas, contidas estatisticamente.

2.6 PLANO HORIZONTAL ALEMÃO

Na medicina existem dois tipos de sistemas de coordenadas. O primeiro se orienta a partir de estruturas extracerebrais, assim por exemplo, é definida a *Deutsche Horizontale*

(Plano de Frankfurt) pelas margens inferiores da órbita e pelas margens superiores dos dois canais auditivos. O segundo baseia-se em estruturas intracerebrais. Para a análise automática de imagens estas são as mais indicadas, porque elas representam melhor a posição das estruturas internas. O sistema de coordenadas estereotático é um exemplo disso. Para a definição do nosso sistema de coordenadas nós utilizamos tais níveis:

- Plano Médio
- Plano de Meynert
- Plano Fastigium

O nível principal de orientação é o Plano Médio (y-z nível), o qual divide um cérebro simétrico em duas áreas espelhadas. O Plano de Meynert é definido pelo eixo de Meynert, que cruza a tangencial com a base do 4º ventrículo. O plano de Meynert posiciona-se perpendicular sobre o plano médio. O Plano Fastigium é vertical em relação aos outros dois planos e ocorre por meio do Fastigium. A origem do nosso sistema de coordenadas concentra-se na interseção (ponto comum) destes três níveis. Ela se localiza na aproximação do eixo de Meynert, e para a definição deste eixo nós não utilizamos, como é normal na medicina, o 4º ventrículo, mas o centro de massa deste.

2.7 REDES NEURAIS

Na realidade, a teoria de redes neurais já começara em 1943 com o clássico artigo de McCulloch e Pitts, no qual os autores, pela primeira vez, conceberam o cérebro como um computador, consistindo de elementos computacionais bem definidos: os neurônios [FAU94].

Redes Neurais são verdadeiras máquinas concebidas para trabalharem segundo o mesmo processo de um sistema nervoso. Seus elementos de processamento são neurônios artificiais, altamente interconectados, que elaboram a soma ponderada das entradas e

aplicam o resultado a uma função de transferência não-linear, para gerar uma saída. Essencialmente, estes modelos consistem dos elementos de processamento, uma topologia de interconexões, e esquemas de aprendizagem obtidos através de modelos matemáticos [LOE91].

2.7.1 NEUROCOMPUTAÇÃO

O cérebro humano é composto por células denominadas Neurônios. O cérebro possui acima de 100 bilhões de neurônios e estes dividem-se em 100 tipos diferentes. Os neurônios são separados em grupos denominados Redes. As redes possuem milhares de neurônios altamente conectados. Então, o cérebro pode ser visto como um conjunto de redes de neurônios [TUR93].

O cérebro humano é o dispositivo mais complexo conhecido pelo homem. A capacidade de pensar, memorizar e resolver problemas tem levado muitos cientistas a tentar modelar a sua operação. Diversos pesquisadores têm buscado criar um modelo computacional que represente a funcionalidade do cérebro, de uma maneira simples. Um destes modelos resultou na Neurocomputação, que tem como objeto de estudo as redes computacionais neurais.

2.7.2 O NEURÔNIO

O neurônio, basicamente, capta o estímulo nos dendritos e o transmite pelo axônio para que atinja um outro neurônio ou outros tipos de células. A captação do estímulo é realizada por receptores sensoriais especializados. Existem diversos tipos desses receptores: mecânicos, térmicos, nociceptores, químicos,... [TAF95]. Conforme Fig. 26.

Os estímulos entram nos neurônios através das sinapses, que conectam os dendritos (ramificações de entrada) de um neurônio com axônios de outros neurônios ou com o sistema nervoso, as quais regulam as quantidades de informações que passam dos dendritos para o neurônio. Os sinais são então passados para o somador (corpo celular), que os adiciona e os aplica a um sensor de limiar, que determina o nível de energia mínima de entrada acima do qual o neurônio dispara.

Se a soma dos sinais é maior que o nível de limiar, o neurônio envia energia através do axônio, de onde a energia é transmitida para outras sinapses (se bem que, muitas vezes, os axônios conectam-se diretamente com outros axônios ou corpos celulares); ou também pode realimentar a sinapse original, mas se a soma for menor do que o limiar nada acontece.

As sinapses têm um papel fundamental na memorização da informação, pois a maioria destas é que armazena a informação. Pode-se imaginar que em cada sinapse a quantidade de neurotransmissores que podem ser liberados para uma mesma frequência de pulsos do axônio representa a informação armazenada pela sinapse.

Em média, cada neurônio forma entre mil e dez mil sinapses. O cérebro humano possui cerca de 100 bilhões neurônios, e o número de sinapses é de mais de 100 trilhões, possibilitando a formação de uma rede muito complexa [FAU94].




Figura 26 - Neurônio Biológico

2.7.3 O ELEMENTO DE PROCESSAMENTO

Um processo similar ocorre nos elementos de processamento em um sistema de computação neural, onde os sinais entram nos elementos de processamento através das conexões ponderadas. A informação está armazenada nestas conexões. Cada sinal que entra pelo sistema, que pode ser positivo ou negativo, é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade. É feita a soma ponderada dos sinais, que produz um certo nível de atividade (Fig. 27).

Um resposta de saída é gerada somente se esse nível de atividade exceder um certo limite (threshold). Caso contrário, nenhuma saída é gerada para o particular elemento de processamento.




Figura 27 - Neurônio Artificial

As conexões ponderadas entre elementos processadores são chamadas de interconexões. A informação está armazenada em um padrão de interconexões, que constitui a memória distribuída da rede. As interconexões também estão envolvidas no processo de aprendizado, que é feito pelo ajuste do peso da interconexão [FAU94].

A operação dos elementos processadores envolve os seguintes passos:

- classificação dos sinais de entrada;
- computação das somas ponderadas individuais;
- combinação das somas ponderadas individuais;

- aplicação da função de transferência na soma.
-

2.7.4 ANALOGIA COM O CÉREBRO

Segue uma analogia do neurônio com o elemento de processamento, demonstrado no Quadro 1.

NEURÔNIO	ELEMENTOS DE PROCESSAMENTO
Dendritos	Entradas
Sinapses	Conexões ponderadas
Somador	Função somadora
<i>Threshold</i>	Função de transferência
Axônio	Saída global

Quadro 1 - Analogia com o Cérebro

2.7.5 REDES NEURAIS ARTIFICIAIS

Uma rede de computação neural é um modelo matemático que consiste em várias unidades simples, semelhantes aos neurônios, denominados elementos de processamento. Estes elementos são organizados em camadas, onde cada elemento tem conexões ponderadas com outros elementos, sendo que estas conexões podem tomar diferentes configurações, dependendo da aplicação particular desejada [LOE96].




Figura 28 - Rede de Computação Neural

A rede neural é, geralmente, constituída de uma camada de entrada, que recebe os estímulos, e de uma camada de saída, que produz a resposta. Algumas redes podem ter uma ou mais camadas internas (escondidas). A capacidade computacional de uma rede neural está nas conexões entre os elementos processadores (Fig. 28).

Uma rede neural artificial pode ser organizada de diferentes maneiras, à semelhança das redes biológicas. Entretanto, nas redes biológicas o processamento das informações é paralelo. Em contrapartida, em redes neurais artificiais simuladas por software, com computação convencional (hardware com arquitetura de Von Neumann), o processamento é limitado por ser serial [TUR93].

Basicamente, uma rede neural artificial é composta de uma coleção de neurônios agrupados em camadas, envolvendo a seguinte estrutura:

- número de camadas de neurônios;
- número de neurônios por camada;
- tipo de conexões;
- grau de conectividade.

2.7.5.1 CAMADAS

Basicamente as camadas de uma rede neural pode ser classificada como:

- Camada de Entrada: processamento dá-se em valores numéricos, onde em alguns casos cada valor de entrada corresponde a um único atributo. O pré-processamento faz-se necessário quando do tratamento de problemas envolvendo atributos qualitativos ou imagens, a fim de convertê-los para valores numéricos equivalentes [TUR93].
- Camada de Saída: Nesta camada encontra-se a solução para o problema proposto. Assim como a camada de entrada, esta não foge a regra, podendo somente assumir valores numéricos. Em caso de utilização de pré-processamento na camada de entrada, não se exige necessariamente que isto ocorra na de saída, porém é trivial a ocorrência em ambas camadas.
-

2.7.5.2 CONEXÕES

Quanto as conexões podemos ter as seguintes considerações:

- Peso das Conexões: Os pesos são elementos fundamentais à rede. Eles exprimem a força relativa, em valor numérico, dos dados introduzidos inicialmente ou às várias conexões que transferem dados de uma camada para outra. São eles que exprimem a importância relativa de cada entrada de um neurônio artificial [FAU94].
- Tipos de Conexões: Rede *FeedBack*, o resultado do processamento pode ser passado tanto para a próxima camada quanto para a camada precedente; rede *Feedforward*, o resultado do processamento passa somente para a próxima

camada; rede *Feedlateral*, o resultado do processamento passa para os elementos da mesma camada, uma vez que ela apresenta conexões laterais [TAF95];

- Função Soma: Efetua cálculos de multiplicação e soma a fim de estabelecer a média dos pesos que compreendem as conexões dos neurônios da camada de entrada [TAF95];
- Função de Transferência: Com base no resultado da função soma, o neurônio produz ou não determinada saída. A partir de então a função de transferência modifica o valor de saída do neurônio para que o mesmo respeite uma determinada faixa de domínio [TAF95].
-

2.7.6 TOPOLOGIAS DE REDES NEURAIIS ARTIFICIAIS

A seguir serão apresentadas as topologias existentes nas redes neurais.

2.7.6.1 REDES DIRETAS (FEEDFORWARD)

São aquelas cujo grafo não tem ciclos. Frequentemente, é possível representar estas redes em camadas; neste caso, são chamadas redes em camadas. Os elementos que recebem sinais de excitação pertencem à camada de entrada. Os elementos que têm sua saída como saída da rede pertencem à camada de saída. Os elementos que não pertencem a nenhuma destas camadas são internos à rede e pertencem a uma ou mais camadas internas (*hidden layers*), conforme demonstrado na Fig. 29.




Figura 29 - **Rede direta com 4 camadas**

2.7.6.2 REDES COM CICLOS

São aquelas cujo grafo de conectividade contém ao menos um ciclo e cujos elementos de processamento apresentam a possibilidade de realimentarem outros elementos. Quando, além disto, envolvem neurônios dinâmicos, são chamadas de recorrentes.

2.7.6.3 REDES SIMÉTRICAS

São aquelas cuja matriz de conectividade é uma matriz simétrica (Fig. 30).




Figura 30 - Rede Simétrica com uma camada interna

2.7.7 TIPOS DE REDES NEURAIS ARTIFICIAIS

As redes computacionais são associativas e podem ser de dois tipos: Autoassociativa e Heteroassociativa.

2.7.7.1 REDE AUTOASSOCIATIVA

Em uma rede autoassociativa, quando o sistema é estimulado por uma informação ruidosa, a rede é capaz de produzir um padrão que tenha um mínimo de ruído. O comportamento deste tipo de rede pode ser descrito pela seguinte expressão:

$$f(X + \#) \rightarrow x(n)$$

onde a função $f(X + \#)$ mapeia o padrão de entrada X , mais algum ruído $\#$ para o padrão de saída x . Dada uma entrada ruidosa, a rede é capaz de inferir uma saída clara livre de ruído [TAF95].

2.7.7.2 REDE HETEROASSOCIATIVA

Uma rede heteroassociativa difere da anterior no tipo de interpretação que ela faz de uma informação ruidosa. Fornecido um padrão ruidoso, este tipo de rede é capaz de produzir uma classe de padrão a que não pertence, necessariamente da mesma classe do padrão original à expressão:

$$f(X + \#) \rightarrow x + \$ (n)$$

onde $f(X + \#)$ representa a função de uma heteroassociativa. Fornecida uma entrada ruidosa, é gerada um versão do padrão x com algum desvio $\$$ relacionado com o ruído $\#$ [TAF95].

2.7.8 MÉTODOS DE CONTROLE DO APRENDIZADO

A monitoração é o processo de controle do aprendizado da rede. Este processo de aprendizado acontece, basicamente, de duas formas: o aprendizado supervisionado e o aprendizado não-supervisionado [TAF95].

2.7.8.1 APRENDIZADO SUPERVISIONADO

O treinamento supervisionado do modelo de rede Perceptron consiste em ajustar os pesos e os *thresholds* de suas unidades para que a classificação desejada seja obtida. Para a adaptação do *threshold* juntamente com os pesos, pode-se considerá-lo como sendo o peso associado a uma conexão, cuja entrada é sempre igual a -1 e adaptar o peso relativo a essa entrada.

Quando um padrão é inicialmente apresentado à rede, ela produz uma saída. Após medir a distância entre a resposta atual e a desejada, são realizados os ajustes apropriados nos pesos das conexões de modo a reduzir esta distância. Este procedimento é conhecido como Regra Delta (Fig. 31).




Figura 31 - Regra Delta

Desse modo, tem-se o seguinte esquema de treinamento:

- Inicie todas as conexões com pesos aleatórios;
- Repita até que o erro E seja satisfatoriamente pequeno ($E = e$);
- Para cada par de treinamento (X, D) , calcule a resposta obtida O ;
- Se o erro não for satisfatoriamente pequeno ($E > e$), então atualize os pesos ($W_{\text{novo}} = W_{\text{anterior}} + \eta E X$).

Onde:

- o par de treinamento (X, D) corresponde ao padrão de entrada e a sua respectiva resposta desejada;
- o erro E é definido como a diferença entre a resposta desejada e a resposta obtida (D - O);
- a taxa de aprendizado η é uma constante positiva que corresponde à velocidade do aprendizado (Fig. 32).

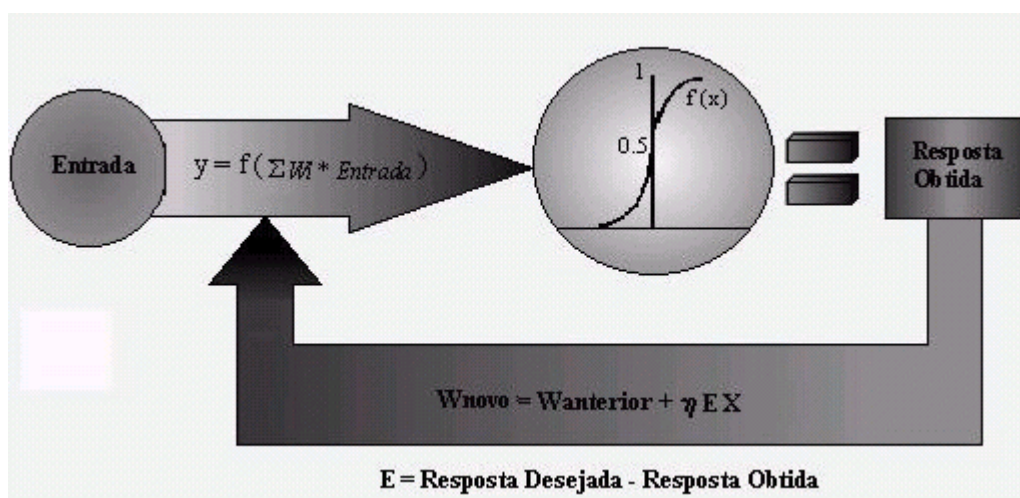


Figura 32 - Esquema de treinamento do Perceptron

2.7.8.2 APRENDIZADO NÃO-SUPERVISIONADO

As redes não-supervisionadas, por sua vez, tem a capacidade de determinar uma correlação entre os possíveis padrões de entrada e são particularmente úteis nos problemas em que as entradas variam com o tempo de forma conhecida (Fig. 33). Podemos considerar este mecanismo de aprendizado como sendo a capacidade que a rede possui de abstrair correlações entre os estímulos de modo a obter as respostas desejadas [MAR96].

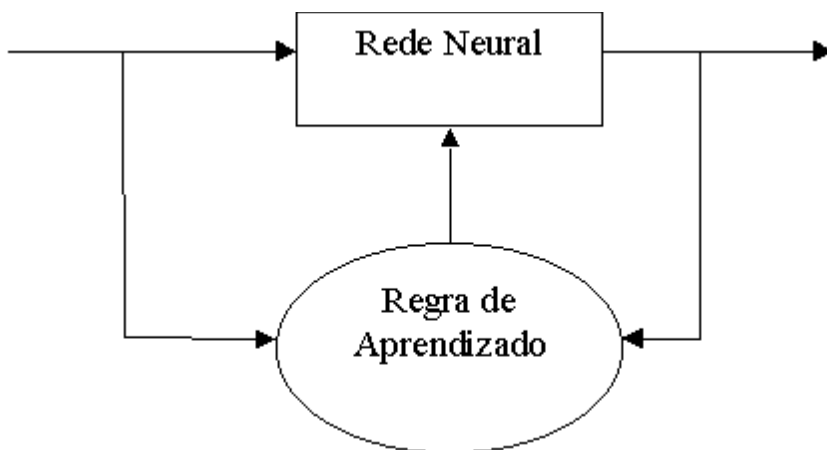


Figura 33 - Aprendizado Não-Supervisionado

2.7.9 MODELOS DE REDES NEURAIS ARTIFICIAIS

A seguir serão apresentados os principais modelos de redes neurais e algumas aplicações.

2.7.9.1 APLICAÇÕES, VANTAGENS E DESVANTAGENS POR MODELO

Modelo	Aplicações Básicas	Ano	Vantagens	Desvantagens
Adaline/Madaline	Filtragem de sinal adaptativo, equalização adaptativa	1960	Rápida e Fácil de implementar	Somente é possível classificar espaços linearmente separáveis
Adaptive Resonance Theory (ART)	Reconhecimento de Padrões	1983	Capaz de aprender novos padrões	Naturaza dos exemplares categóricos podem

				mudar com o aprendizado
Backpropagation Perceptron	Reconhecimento de padrões, filtragem de sinal, controle robótico, compressão de dados, segmentação de sinal, etc.	1974- 1986	Operação rápida, bem compreendida e com muitas aplicações de sucesso	Tempo de treinamento longo
BAM – Memória Associativa Bidirecional	Heteroassociativa (memória endereçada por conteúdo)	1987	Simples, prova clara da estabilidade dinâmica	Capacidade de armazenamento e precisão recuperação pobres
Boltzmann Machine, Cauchy Machine	Reconhecimento de padrões (imagens, sons, radar), otimização	1984	Capaz de formar representação ótima das características dos padrões	Tempo de aprendizado longo
Brain-State-in-a-Box (BSB)	Revocação autoassociativa	1977	Bom desempenho	Incompleta em termos de aplicações em potencial
Hopfield	Evocação autoassociativa, otimização	1982	Simples e estabilidade dinâmica	Incapaz de aprender novos estados
Neocognitron	Reconhecimento de caracteres manuscritos / imagens	1975	Capaz de reconhecer padrões independente da escala, translação e rotação	Estrutura complexa
Quantização de Vetor de aprendizagem	Revocação autoassociativa (complementação de uma padrão a outro parcial apresentado), compressão de dados	1981	Capaz de auto- organizar vetores	Treinamento lento
Recurrent	Controle robótico, reconhecimento de fala, previsão do elemento sequencial	1987	Excelente para classificação, mapeamento de informações variando no tempo	Rede complexa
Redes de ligações funcionais	Classificação, mapeamento	1988	Rápida para treinar	Não é claro o modo de identificar funções adotadas

Time-Delay	Reconhecimento de fala	1987	Rápida operação	Janela fixada para a atividade temporal representada
------------	------------------------	------	-----------------	--

FONTE: [LOE96]

Quadro 2 - Aplicações - Redes Neurais

2.7.9.2 MODELO PERCEPTRON

Perceptron foi a primeira rede neural a emergir. Possui o conceito substancial de neurônio artificial o qual é ainda hoje usado, onde cada neurônio computa uma soma ponderada de suas entradas, e passa esta soma em uma função não-linear com limiarização, conforme Fig. 34. Credita-se a Frank Rosenblatt a criação do Perceptron, projetado para o reconhecimento de padrões e para servir como ferramenta de pesquisa de modelagem de possíveis mecanismos cerebrais [LOE96].

A rede neural perceptron é formada pelos seguintes elementos [TAF95]:

- camada de entrada: cada elemento da camada de entrada faz a distribuição do sinal que ele recebe para todas as unidades de processamento;
- neurônios: são constituídos de unidades sigma (\square) e de funções de transferência (T). As unidades sigma fazem a soma ponderada dos sinais vindos pelas conexões como os elementos de entrada. As funções de transferência determinam a saída de cada neurônio (unidade de processamento) em função da soma ponderada.




Figura 34 - Rede Neural Perceptron

Na rede apresentada pela Figura 34 temos:

- x : sinais de entrada
- w : peso da conexão entre a unidade de entrada i e a unidade de sigma j , onde $i=[1,n]$ e $j=[1,m]$
- s : soma ponderada da unidade sigma
- y : sinal de saída do neurônio

As redes perceptron tem apenas uma camada de processamento. Não existe um procedimento para ajustamento de pesos em redes Perceptrons com mais de uma camada (ao menos quando Perceptron foi criado). Estes problemas foram superados em modelos de redes que surgiram a partir dos anos 80 com o desenvolvimento de técnicas de aprendizado como, por exemplo Backpropagation. Mas, estas redes receberam outros nomes. Deixaram de ser Perceptrons [TAF95].

Para o funcionamento da rede, um padrão de entrada é apresentado à camada de entrada do Perceptron com n unidades, o que significa um vetor de comprimento n , um valor para cada elemento na camada de entrada. Calcula-se a entrada como sendo a soma ponderada de todas as ativações da primeira camada (esta soma ponderada é obtida pelo produto do vetor de entrada da primeira camada e a matriz de pesos). Deste valor obtido é

subtraído um valor limiar (que é fixado para cada elemento). O resultado é aplicado à função de transferência para obter a ativação do elemento. Portanto a ativação do j-ésimo elemento de processamento é dado por (Fig. 35):

$$s_j = \sum_i w_{ij} \cdot x_{ij} + w_{0j}$$

$$y_j = f(s_j) = \begin{cases} +1 & \text{se } s \geq 0 \\ -1 & \text{se } s < 0 \end{cases}$$

Figura 35 - **Função de Transferência**

Onde

- Y_j – é a ativação do j-ésimo elemento
- f – é a função de transferência
- X_{ij} – é a i-ésima entrada do elemento
- W_{ij} – é o peso na conexão da entrada i para o j-ésimo elemento; $j=0$ é o viés que controla o valor limiar.

O Perceptron suporta um aprendizado supervisionado, o que significa que para treinar a rede um conjunto de dados de treinamento deve ser construído e padrões de treinamento devem ser definidos.

No caso do Perceptron, a regra de aprendizagem é muito simples. É modificado cada peso (conexão) de acordo com a expressão (Fig. 36):

$$w_{ij} \leftarrow w_{ij} + \mu \cdot x_{ij} \delta_j$$

Figura 36 - **Regra de Aprendizagem**

2.7.9.3 MODELO FEEDFORWARD / BACKPROPAGATION

O modelo Feedforward com aprendizado Backpropagation, surgiu por meados da década de 80 e constitui, segundo pesquisadores, a mais difundida e largamente usada entre todas arquiteturas e modelos de redes neurais conhecidas [WIL95]. As inovações incorporadas em relação aos modelos existentes até então foram as múltiplas camadas, com a possibilidade de valores de entradas e saídas contínuos (ex. 1.0001 à 2.9999).

O modelo apresenta limitações quanto ao número de camadas, pois a partir de certa quantidade, as camadas anteriores são repetidas, de forma a não demonstrar avanço no processo de convergência [LOE96]. Tal modelo utiliza-se de valores contínuos (ex. 0.0001 à 0.9999), o que difere do modelo *Perceptron* que utiliza valores discretos (ex. 0 ou 1).

Uma aplicação modelada nesta topologia, necessita de padrões de entrada e saída, para a qual a rede converge e se estabiliza, constituindo o que denomina-se de treinamento ou aprendizado da rede. Este modelo utiliza-se de aprendizado supervisionado, ou seja, a cada padrão de entrada está associado a uma saída desejada.

Os Elementos de Processamento das camadas ocultas dão ao modelo a capacidade de abstração e generalização, ou seja, é capaz de classificar um padrão complexo mesmo quando este não pertenceu ao conjunto de treinamento. A rede é, portanto imune a pequenas falhas.

A forma sistemática pela qual os valores são passados de uma camada a outra é a seguinte: a soma ponderada de cada elemento de processamento com os pesos associados às conexões existentes entre os neurônios, feita pelo módulo somador, é levada ao módulo de ativação que gera um sinal de saída (Fig. 37). Este sinal de saída será a entrada dos elementos da próxima camada.

$$Y_j = \sum_{i=1}^n X_i \cdot W_{ij}$$

Figura 37 - Função somadora do EP

Onde:

- Y_j = saída da rede neural do elemento j ;
- \sum = somatório dos valores de entradas multiplicados por seus pesos;
- X_i = valor de entrada do índice i ;
- W_{ij} = peso associado ao elemento j de índice i .

O treinamento deste modelo de rede consiste em ajustar os pesos de conexões das camadas para que o conjunto de entradas atinja o conjunto de saídas desejadas. O algoritmo de treinamento introduz os pares de entradas na rede, calcula as saídas (função soma e transferência) e verifica se as saídas obtidas com o cálculo estão próximas das saídas desejadas, considerando a taxa de erro. Caso o erro seja superior ao parametrizado para o modelo, os pesos serão corrigidos da saída para a entrada. Estas operações são repetidas quantas vezes forem necessárias até que a rede assimile os padrões (pares de entrada) a ela submetida.

A revocação é feita diante dos pesos das conexões armazenadas em arquivos. Nesta etapa, um novo padrão de entrada é oferecido (como par de entrada) a rede, ela computa e gera uma saída.

Sua rápida operacionalização, apresentando capacidade de generalização, robustez e abstração são suas principais vantagens. O fato de requerer um longo tempo de treinamento, em função da necessidade de estabilização e convergência da rede é sua desvantagem, segundo Loesch [LOE96].


2.7.10 FASES DE UM PROJETO DE REDES NEURAIIS

A aplicação dessa tecnologia tem variado muito, mas, de uma forma geral, o objetivo é quase sempre o mesmo, reconhecer e classificar padrões, e, possivelmente, também prever e generalizar informações. Sabe-se que um projeto utilizando redes neurais deve ser

orientado para esse tipo de finalidade. Seria inconveniente desenvolver um projeto dessa ordem para, por exemplo, cadastrar clientes de uma loja. Seria mais condizente, porém, aplicar esse tipo de tecnologia para classificar o perfil dos clientes cadastrados dessa loja. O campo de aplicação de redes neurais é extenso. Deve-se tomar muito cuidado não somente ao aplicá-las, mas, também com o onde, o como e o quando aplicá-las. A rede, apesar de vasta aplicação, possui seus limites e sua área específica de atuação.

Uma vez diante de um projeto de uma rede neural, não pode-se mais pensar em procedimentos, regras ou fórmulas algorítmicas de processamento de dados, mas em tipos de dados de entrada, dados de saída e tratamento de dados.

A rede baseada nos dados terá dois momentos de explicitação do processamento: o momento de aprendizado e o momento de utilização (a aplicação da rede de fato). Deve-se atentar para o fato de que, esses dois momentos de operação de uma rede neural, apesar de serem próximos, são bem distintos e aplicados em períodos diferentes no projeto da rede. O aprendizado é um processo de ajuste dos pesos das conexões em resposta à quantidade de erros gerada pela rede. Ou seja, a rede possui a propriedade de modificar-se em função da necessidade de aprender a informação que lhe foi apresentada anteriormente. Já o processo de utilização é a maneira pela qual a rede responde a um estímulo de entrada. A principal diferença entre a utilização e o aprendizado é que nenhum ajuste de pesos é efetuado, e, da mesma forma, não há cálculo para a quantidade de erros ocorridos [TAF95].



Apesar do projeto de rede possuir essas duas fases distintas, aprendizado e utilização, o mesmo pode ser organizado num processo de implementação de 4 fases diferentes para consolidar uma utilização mais segura. O ciclo de vida de uma rede, como é o conhecido, é composto pelas seguintes fases: Definição, Treinamento, Utilização e Manutenção [Figura 19].

Essas fases do projeto podem ser divididas em muitas outras fases intermediárias. Essas 4 fases, porém, definem de uma forma mais generalizada os contextos diferentes em que uma rede pode-se encontrar.

2.7.10.1 CONCEPÇÃO DA REDE NEURAL

As fases de Definição e Treinamento são as fases iniciais do projeto, seguidas, depois, das fases de Utilização e Manutenção da rede. Seria interessante acrescentar, ainda, uma fase que antecederesse a todas as outras 4 fases, a fase de concepção [Figura 20].



Essa fase constitui o planejamento da construção da aplicação, ou seja, a validação da proposta e a seleção do paradigma neural. Neste ponto devem ser colocados em pauta, e devidamente julgados, aspectos que, por quaisquer outros motivos, não recaiam por surpresa, posteriormente, sobre o projeto. Aspectos como tecnologia inadequada, dados incompletos, ou dados com ruídos [TAF95].


2.7.10.1.1 DEFINIÇÃO DA REDE NEURAL

A fase de Definição é delicada, pois envolve, além da escolha do modelo da rede, a obtenção do conjunto de variáveis significativas para a resolução do problema. Essa obtenção envolve, além da identificação das variáveis que estão relacionadas com o problema, a remoção de variáveis não confiáveis para o processo, ou cujo uso seja impraticável por razões técnicas ou econômicas [TAF95].

A definição também é entendida como uma seleção do paradigma neural na qual são levados em consideração os seguintes aspectos da rede:

- a) tamanho da rede – selecionado o tamanho da rede, será delimitado também o escopo do problema. Por isso, a escolha e a visualização desse escopo é essencial para selecionar o tamanho da rede neural.
- b) tipo de problema a ser resolvido – este é mais um ponto importante pois o tipo de saída limita o paradigma a ser selecionado, A saída pode ser interpretada de diversas formas: classificação, padronização e otimização.
- c) classificação – faz o mapeamento da entrada em categorias discretas.
- d) padronização – neste tipo de saída, neurônios múltiplos potencialmente ativos formam um padrão de respostas às entradas apresentadas.
- e) otimização – é um padrão especial interpretado como conjunto de decisões. A saída deverá representar a entrada, porém com bem menos neurônios, ou seja, houve uma compactação.
- f) tipo de associação – o tipo de associação é dividido basicamente em dois: memória auto-associativa (aprendizado não supervisionado) e memória Heteroassociativa (aprendizado supervisionado).

Para o desenho da rede é preciso especificar os valores e as condições iniciais para o paradigma selecionado. Essas especificações acontecem em 3 níveis: neurônio, rede e treinamento [Figura 21].



Para o nível de neurônios é escolhido o tipo de entrada, a integração dessas entradas e a função de transferência do neurônio. No nível de rede, a escolha é feita para o número de camadas, os números e os tipos dos neurônios de entrada, saída e intermediários, além do tipo de conectividade. Deve-se tomar certo cuidado com a escolha do número de camadas, pois, quando o número de camadas intermediárias é muito grande, pode acabar fazendo com

que a rede memorize os dados em vez de generalizá-los. E finalmente, para o nível de treinamento é escolhido o algoritmo de aprendizado juntamente com o parâmetro de aprendizado.

2.7.10.2 TREINAMENTO DA REDE NEURAL

A fase de treinamento compreende, inicialmente, a definição de um dos dois conhecidos de métodos de treinamento: o aprendizado supervisionado e o aprendizado não-supervisionado [TAF95].

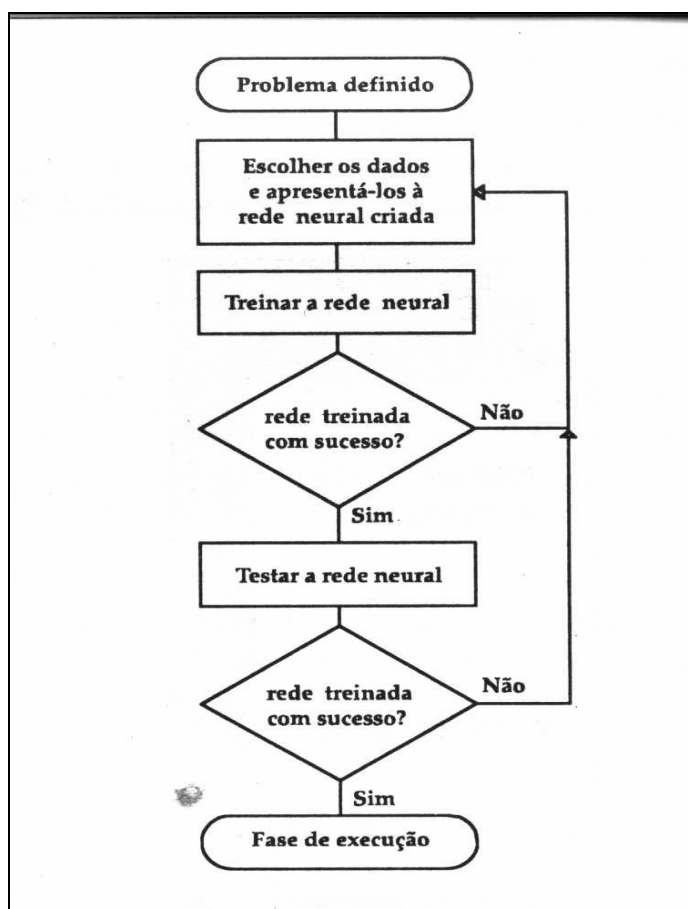
- a) aprendizado supervisionado – requer, para o treinamento, pares de dados constituídos de um padrão de entrada e um padrão de saída (valor desejado na saída);
- b) aprendizado não-supervisionado – o treinamento não-supervisionado classifica padrões de entrada internamente, não exigindo a definição de valores desejados na saída.

Quando fala-se de pares de dados para o modelo supervisionado, fala-se de dois vetores de dados. Cada vetor de entrada possui um vetor correspondente de saída. Estes dois vetores distintos, não necessariamente de mesmo tamanho, possuem uma relação entre si.

Quando fala-se de treinamento não-supervisionado, não existe a necessidade do segundo vetor pois, como não existe uma supervisão (a saída Y para a entrada X), não existe também a necessidade de existir o vetor de saídas.

O treinamento, pode-se assim dizer, inicia quando um exemplo é mostrado à rede e termina quando todas as conexões estão devidamente ajustadas (treinadas) para reconhecer todos os exemplos mostrados à rede. A partir deste momento a rede neural está pronta para a fase de testes e, a seguir, para a execução [Figura 22].

Quanto ao conjunto de dados que será submetido à rede, pode-se dizer que, quanto mais completo o conjunto, mais tempo computacional será utilizado para ajustar as conexões e, certamente, melhor será o seu treinamento.



Com o intuito de se obter uma qualidade representativa dos dados para formar um bom conjunto deve-se levar em conta aspectos como:

- tipos dos dados a serem coletados – buscar dados que tenham um grau de pertinência elevado em relação ao escopo do problema;
- quantidade desses dados para obter um número elevado de conjuntos de dados para que, submetidos à rede, efetuem um bom treinamento. Vale a regra: quanto maior a experiência melhor o desempenho;
- preparação dos dados – dependendo do tipo dos dados que serão submetidos a rede, estes devem sofrer uma preparação para melhor representar a informação.

Essa fase (treinamento) costuma receber atenção especial, pois quanto melhor o conjunto de treinamento, melhor o resultado da atuação da rede.

2.7.10.3 UTILIZAÇÃO DA REDE NEURAL

Essa fase é a execução da rede, iniciando quando uma entrada é apresentada à rede e terminando com o rede gerando uma saída.

Antes de prosseguir com a utilização em campo, é indispensável, no mínimo, um teste na rede para nela verificar a incidência ou não de erros. Para tal atitude, é recomendável a apresentação de uma série de casos teste e avaliar profundamente as respostas geradas. Para os testes devem-se utilizar casos já experimentados e casos completamente novos, ou seja, ainda não vistos pela rede. Usem-se também casos de rotina e casos extremos. Contudo, é bom lembrar que, para avaliar as respostas da rede deve-se antes determinar um limite de aceitação da resposta da rede. Se a fase de testes for satisfatória, considera-se a rede bem treinada para a finalidade em questão [TAF95].

Dependendo da maneira que se utiliza a rede, ela apontará ou não uma performance satisfatória, e, mostrando-se inadequada, deverá ser avaliada em termos de origem do problema, que por sua vez, poderá ocorrer tanto na fase de definição da rede quanto na fase de treinamento, sem excluir, em última análise, a fase de concepção.

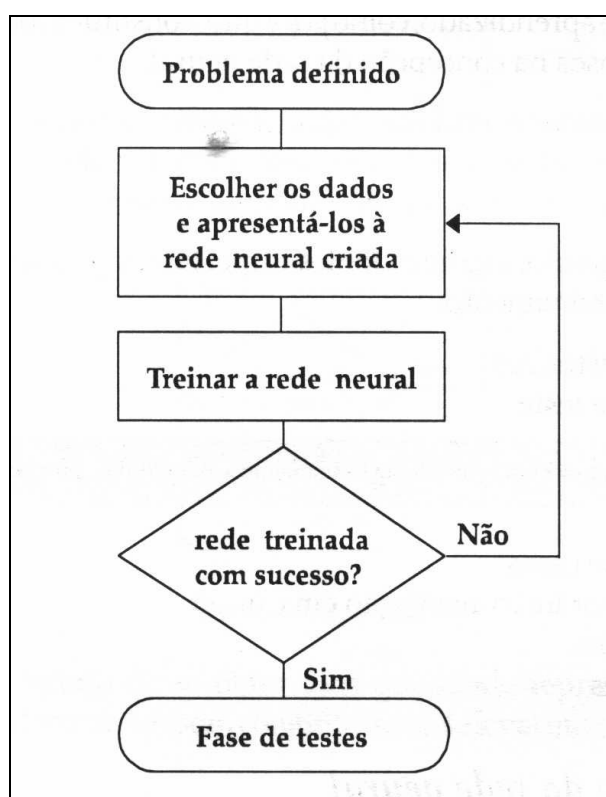
Lembramo-nos que, apesar de terem sido feitos testes para qualificar um treinamento, nada impede que apareçam falhas durante a fase de utilização. Afinal, uma rede neural não é treinada para 100% de acertos, uma vez que não foi treinada com 100% dos casos possíveis. A inviabilidade para tamanha precisão é muito alta.

2.7.10.4 MANUTENÇÃO DA REDE NEURAL

Sobre a manutenção, pode-se dizer que a maioria das redes são treinadas para solucionar problemas dinâmicos. Uma avaliação contínua, portanto, é necessária e indispensável para garantir uma boa utilização. À medida que o tempo avança, poderão surgir novos conjuntos de dados reais ainda desconhecidos pela rede, e, dessa forma,. Será necessário um novo aprendizado ou, dependendo do caso, até mesmo uma nova definição [TAF95].

Caso os testes indiquem erros significativos, o projetista da rede neural deve resolver o problema iniciando pelo processo de treinamento [Figura 23]. Examine a qualidade dos casos usados, a representatividade, os parâmetros do algoritmo usado para treinar. Preste atenção também na arquitetura utilizada na rede, sua conectividade e as características dos neurônios.

Sendo uma manutenção, um processo dinâmico, é bom prestar atenção em detalhes como a queda de precisão durante o processo de utilização, como também nos problemas que possam vir a ser detectados na avaliação do sistema realizado de tempos em tempos.



3 ADAPTAÇÃO AUTOMÁTICA DO ATLAS CEREBRAL

Usualmente o exame radiológico é requisitado por quatro razões básicas: visualização, quantificação, localização e triagem. O radiologista escolhe o método de melhor indicação para manipular imagens, permitindo assim uma melhor visualização, como ajustar os níveis de cinza de uma imagem tomográfica para exibir as regiões de maior interesse, ou ainda, usar as técnicas de filtragens digitais para remover ruídos, para detecção de bordas e para limpar imagens borradas.

As tarefas de um sistema de análise de imagens são basicamente a determinação, parametrização e coordenação de seqüências de análise para imagens específicas. Com isso, para a adaptação do atlas, as imagens de tomografia computadorizada foram submetidas ao processamento por uma seqüência específica de diferentes processos de análise, que vão desde filtros de intensificação de contraste até a classificação dos segmentos de imagens extraídos. O processo de reconhecimento de uma imagem consiste, via de regra, de uma composição de filtros, de detectores de bordas, regiões e texturas e de métodos de reconhecimento e classificação de objetos e padrões. A adequação de um determinado método ou processo para a execução de uma determinada tarefa depende fortemente da natureza e dos parâmetros da imagem a ser analisada. Portanto uma metodologia que permita uma adaptação dinâmica e otimizada desse processo se faz necessária.

3.1.1 METODOLOGIA PARA ADAPTAÇÃO DO ATLAS

Para certos propósitos, tais como cirurgias ou radioterapia, a localização precisa da lesão é a principal razão para estudo. A localização também é crucial para procedimentos radiológicos intervencionistas, tais como biópsias aspirativas com agulha e drenagem de

abscessos. Os radiologistas analisam as imagens para determinar o melhor local para chegar à lesão, e para determinar o ângulo de aproximação e a profundidade.

A seguir serão apresentados os procedimentos necessários para a adaptação automática do atlas cerebral digital, onde foi realizada uma série de testes até chegarmos a uma solução aceitável.

3.1.1.1 DEFINIÇÃO DAS ESTRUTURAS

O primeiro passo para a adaptação do atlas foi identificar quais estruturas serviriam como referência atendendo as relações de biometria do paciente.

Então foi definido que seria usado o Plano Horizontal Alemão como referência e para isso seria necessário identificar a base do quarto ventrículo e os olhos, que são as estruturas de referência do plano.

O Plano Horizontal Alemão é calculado a partir da base do quarto ventrículo, uma estrutura intracerebral de fácil visualização, e os centros de ambos os olhos. Este plano foi escolhido por atender aos requisitos de relacionamento com a biometria do paciente (posicionamento do quarto ventrículo e olhos) e possibilidade de cálculo com base nas imagens tomográficas.

3.1.1.2 PRÉ-PROCESSAMENTO

Após a definição de quais estruturas seriam referência para a auto adaptação do atlas, o próximo passo é identificar essas estruturas de forma automática.

A estrutura do processo de identificação pode ser sintetizada pela ordem:

- Aquisição da imagem;
- Tratamento da imagem;
- Obtenção de atributos;
- Identificação (Rede Neural).

As fases serão tratadas em detalhes nos próximos tópicos, visando o entendimento do processo.

3.1.1.3 AQUISIÇÃO DA IMAGEM

A aquisição das imagens é feita através de um tomógrafo. Apesar dos recentes avanços da Ressonância Magnética (RM), a Tomografia Computadorizada (TC) mantém-se como indispensável na avaliação inicial dos pacientes com anomalias no cérebro, sendo capaz de fornecer informações que complementam a estimativa clínica sobre sua provável evolução. Por exemplo, no caso de AVEs (Acidentes Vasculares Encefálicos), podem fornecer dados sobre a localização topográfica e o volume dos hematomas, a presença de deslocamento das estruturas neurais e de lesões associadas, assim como dados sobre a possível origem do processo, os quais têm implicações sobre o tratamento e prognóstico evidentes.

Neste exame, um feixe de raios X do calibre de um lápis gira ao redor do paciente gerando uma imagem ("fatia") do mesmo. São formados pequenos blocos de tecidos (voxels), cada um com um determinado valor de absorção conforme as características do tecido que foi gerado a imagem. Estas imagens são reconstruídas em um plano bidimensional (pixels) na tela do computador, gerando uma série de imagens para cada cabeça. Conforme demonstrado na Fig. 38.




Figura 38- Esquema do tomógrafo

Na tomografia computadorizada utiliza-se feixe de raios X altamente colimado e a leitura da radiação é feita por detectores especiais muito sensíveis. A radiação é emitida em torno do corpo com movimento continuado do tubo de raios X e o sinal luminoso periodicamente gerado nos detectores é transformado em impulsos elétricos, quantificados por computador. A imagem é reconstruída matematicamente, para integrar milhares de leituras de atenuação, e é numérica, mas pode ser apresentada analogicamente numa tela de televisão. Esta imagem é na realidade tridimensional, constituída por elementos de volume de uma matriz com espessura típica entre 1.5 e 10 mm. Os elementos de superfície da matriz (pixels) definem a resolução espacial, que varia entre 0.3 e 1.5 mm² (milímetros quadrados). A discriminação espacial da tomografia computadorizada é inferior à da radiografia convencional.

No diagnóstico por TC toma-se a densidade da água como valor 1; as estruturas mais densas que a água, por exemplo a gordura, tem densidades negativas, sendo a do ar a mais negativa, representada por -500.

O osso aparece em branco e o ar em preto, as demais estruturas intermediárias têm tons de cinza mais claro ou escuro, dependendo da densidade correspondente. O uso do contraste iodado por via venosa é de grande importância em TC. Ele se acumula em alguns locais de maneira variável, mas apenas onde há quebra de barreira hematoencefálica. Nestes pontos, as neoplasias cerebrais por exemplo, a densidade do tecido patológico é aumentada e diz-se que houve realce anormal do contraste.

Limitações que devem ser mencionadas incluem aneurismas, só visíveis de maneira confiável quando relativamente volumosos (maiores que 1 cm), e lesões isodensas ao liquor, quando nele inclusas, sem efeito de massa associado, como cistos parasitários ventriculares e cisternais.

A tomografia computadorizada contribui pouco na investigação de doenças comuns que não tem manifestação radiológica, como as meningites agudas não complicadas, convulsões generalizadas na infância e doenças psiquiátricas não orgânicas. Para uma vasta gama de enfermidades, entretanto (anomalias congênitas, doenças vasculares, infecciosas, neoplasias, doenças hereditárias degenerativas, traumas), a tomografia computadorizada representa o passo mais importante e freqüentemente final no diagnóstico e planejamento terapêutico.

As imagens utilizadas para esse trabalho, obtidas através de um tomógrafo, são convertidas para um padrão DICOM. Tais arquivos foram importados para o banco de dados DICOM para serem visualizados.

Através de um editor de imagens DICOM tem-se a possibilidade de observar a série de imagens e executar tarefas relacionadas à análise e ao tratamento destas.

3.1.1.4 TRATAMENTO DA IMAGEM

Para chegar a uma solução confiável, várias seqüências de processamento foram testadas. Alguns operadores matemáticos como Erosão, Dilatação, Esqueletonização e algoritmos de segmentação como Munford-Shah, Watershed também fizeram parte dessas seqüências.

Os melhores resultados foram obtidos com a seqüência descrita a seguir, que são realizados em todos os cortes (*slices*) de cérebro da série de imagens de tomografia carregada.

O primeiro passo é exportar a imagem correspondente ao corte (*slice*) para uma imagem de 16 bits com valores originais de HU (*hounsfield*). Esse processo foi realizado para permitir a possibilidade de trabalhar sempre com os mesmos valores independente de window setada pelo médico. Médicos costumam alterar window com o objetivo de melhorar a visualização estruturas, isto é, as imagens são carregadas como imagens de oito bits e a paleta de cores é alterada levando em conta valores de windowWidth e windowCenter. Tais valores indicam a largura da paleta (quantidade diferente de tons de cinza) e o seu centro na escala. Mas estes parâmetros não indicam valores na paleta e sim valores na escala de *Hounsfield*. Esta escala define valores entre -1000 (corresponde ao preto) e +1000 (corresponde ao branco). Sendo assim, é necessária uma conversão entre a escala de cores de uma imagem de 16 bits e a escala de *hounsfield* para poder ocorrer a conversão para oito bits, ocorrendo uma redução menor na quantidade de informação quando comparado à redução direta de 16 para oito bits.

Posteriormente é utilizada a seguinte seqüência de pré-processamento para filtrar as estruturas:

- Threshold
- Opening
- Closing

A técnica de limiarização (Threshold) consiste em definir um valor de limiar para a cor de um pixel. Pixels com valor de cor acima de limiar se tornam pretos e de valor abaixo se tornam brancos. Isso permite a segmentação de estruturas através do seu valor de densidade radiológica. Para eliminar os ruídos resultantes é realizada uma operação morfológica chamada Opening seguido de uma operação de closing. O principal tipo de ruído que essas operações morfológicas tem como objetivo eliminar são estruturas intracerebrais que podem prejudicar a identificação automatizada.

A forma de utilização dessa seqüência de operações para pré-processar as imagens tanto para identificar olhos como para identificar base de quarto ventrículo são tratados a seguir.

Configuração de cada operação para a identificação da base do quarto ventrículo é dada conforme abaixo.

Após uma extensiva análise em aproximadamente 200 séries de cortes tomográficos de cabeça de pacientes e a partir de estatísticas geradas a partir desse estudo configurou-se a seguinte seqüência de pré-processamentos:

Threshold – foi verificado que o quarto ventrículo possui valores de pixels entre 980 a 995. Com isso foi aplicado um threshold na imagem exportada em 16 bits gerando uma imagem binária (pixels entre a faixa de 980 e 995 recebem 0 e o restante recebe 1). Conforme Fig. 39.




Figura 39 - Threshold

Opening - utilizando como entrada a imagem gerada pelo threshold foi aplicado um opening utilizando como elemento estruturante um disco com diâmetro de 15, visando eliminar ruídos na imagem. Conforme Fig. 40.




Figura 40 - Opening

Closing - utilizando como entrada a imagem gerada pelo opening foi aplicado um closing utilizando como elemento estruturante um disco com diâmetro de 5. Conforme Fig. 41.




Figura 41 - Closing

Configuração de cada operação para a identificação dos olhos:

Threshold - foi verificado que os olhos possuem valores de pixels entre 980 a 1003. Com isso foi aplicado um threshold na imagem exportada em 16 bits gerando uma imagem binária (pixels entre a faixa de 980 e 1003 recebem 0 e o restante recebe 1). Conforme Fig. 42.




Figura 42 - Threshold

Opening - utilizando como entrada a imagem gerada pelo threshold foi aplicado um opening utilizando como elemento estruturante um disco com diâmetro de 15. Conforme Fig. 43.




Figura 43 - Opening

Closing - utilizando como entrada a imagem gerada pelo opening foi aplicado um closing utilizando como elemento estruturante um disco com diâmetro de 5. Conforme Fig. 44.




Figura 44 - Closing

Após esses pré-processamentos já pode-se identificar de maneira clara a base do quarto ventrículo e os olhos e em quais cortes se encontram.

3.1.1.5 OBTENÇÃO DE ATRIBUTOS

Visando identificar os objetos da imagem, foi necessário primeiramente saber como diferenciar o objeto de interesse do restante da imagem, através de sua cor, textura ou forma, e posteriormente identificar o procedimento para fazer a separação do objeto de forma automática computacionalmente.

Uma vez corretamente identificados, os objetos ou figuras de estudo devem ser classificados conforme algum conjunto de regras determinadas. A escolha desse conjunto deve seguir padrões notoriamente relevantes para identificação do objeto, permitindo uma grande diversidade de aspectos em consideração.

As características consideradas relevantes para a identificação da base do quarto ventrículo e dos olhos são:

- Área
- Perímetro
- Bounding Box
- Centro

Foi utilizado como heurística a posição do quarto ventrículo, onde foi recortado uma região de 128 x 128 pixels nas proximidades do quarto ventrículo (figura 45). Da mesma maneira foi extraída uma região como heurística nas proximidades dos olhos, onde foi recortado uma região de 256 x 128 pixels.

Após isso, através de um algoritmo de segmentação por crescimento de regiões (Mumford-Shah), são retiradas todas as estruturas que estiverem dentro dessa região. Onde posteriormente são calculados os atributos das mesmas (Fig. 45).




Figura 45 - Imagem resultante do recorte de 128 x 128 nas proximidades do quarto ventrículo

Atributos calculados:

Área - considerando que já se possui uma imagem binária resultante do pré-processamento, temos uma imagem com valores 0 e 1, onde 1 demarca fundo e 0 demarca figura. Obtemos então a área somando o total de pixels iguais a 0.

Perímetro - pode ser obtido identificando-se quantos pixels 0 tem vizinhos 1, o perímetro será a soma do total desses pixels.

Bounding Box - é um retângulo que tangencia todas as maiores extremidades da figura. Conforme na Fig. 46.




Figura 46 - Bounding Box

Centro – é uma coordenada obtida através de integrais calculadas sobre a imagem em questão. Muitos objetos possuem um ponto, eixo ou plano de simetria. Nesse caso, o centro de massa do objeto está sobre esse ponto, eixo ou plano.

3.1.1.6 IDENTIFICAÇÃO

Para a identificação da base do quarto ventrículo e dos olhos foi utilizada uma rede neural artificial. O uso de redes neurais é comumente aplicado ao reconhecimento de padrões dado o potencial de aprendizado de funções do sistema, que simula uma rede neural natural em muitos aspectos e utilizando uma metodologia simples e eficaz bastando encontrar informações nas imagens que sejam relevantes para a rede.

A topologia escolhida foi a de uma rede direta, devido a possibilidade de conhecer o resultado esperado para cada padrão de entrada. O modelo de rede neural escolhido para a identificação da base do quarto ventrículo foi a MLP Backpropagation. A rede foi construída utilizando-se a seguinte configuração:

- 8 (oito) neurônios de entrada, sendo:

- 4 neurônios com as coordenadas do bounding box;

- 2 neurônios com a coordenada do centro;

- 1 neurônio com o perímetro;

- 1 neurônio com a área.

- 5 neurônios na camada intermediária;

- 2 neurônios na camada de saída: 1 neurônio identificando a base do quarto ventrículo, e 1 neurônio identificando todas as estruturas que não são bases de quarto ventrículo (lixo).

Para o processo de identificação dos olhos também foi usada uma rede com aprendizado Backpropagation. A rede foi construída utilizando-se a seguinte configuração:

- 8 (oito) neurônios de entrada, sendo:

- 4 neurônios com as coordenadas do bounding box;

- 2 neurônios com a coordenada do centro;

- 1 neurônio com o perímetro;

- 1 neurônio com a área.

- 5 neurônios na camada intermediária;

- 3 neurônios na camada de saída: 1 neurônio identificando o olho esquerdo, 1 neurônio identificando o olho direito e 1 neurônio identificando todas as estruturas que não são olhos (lixo).

A fase de treinamento da rede para a identificação da base do quarto ventrículo foi realizada com 400 segmentos de imagem, incluindo segmentos que eram a base do quarto ventrículo e segmentos que não eram. Da mesma maneira foi realizado o treinamento com os olhos.

3.1.1.6.1 EXEMPLO APLICADO AO RECONHECIMENTO DE BASE DO QUARTO VENTRÍCULO



Figura 47 - Estrutura retirada de uma imagem pré-processada

Depois de calculado os atributos da Fig. 47 chega-se ao seguinte resultado:

- Bouding Box = 50 - 60 - 80 - 77

- Área = 274

- Perímetro = 61

- Centro = 65 - 67

Portanto a rede neural na fase de treinamento teria a seguinte configuração:

- Camada de entrada = 50, 60, 80, 77, 274, 61, 65, 67

- Camada de saída = 1, 0 (o primeiro neurônio ativo significa que a estrutura é a base do quarto ventrículo)

3.1.1.7 SEQUÊNCIA DE PROCESSAMENTO PARA DETECÇÃO DOS LIMITES DO ATLAS

Para que fossem encontradas as extremidades do atlas foi necessário elaborar uma sequência de processos para a extração do cérebro das imagens de tomografia computadorizada. Como os limites do atlas são dados pelas linhas mais externas do cérebro, com isso seria possível calcular o bounding box de todos os cortes e calcular esses limites.

A sequência de processamento foi utilizada para cada corte da série de imagens tomográficas carregadas.

Analizando aproximadamente 200 séries de cortes tomográficos de cabeça de pacientes e a partir de estatísticas geradas a partir desse estudo configurou-se a seguinte sequência de pré-processamentos:

- Threshold – foi verificado que o cérebro possui valores de pixels entre 1005 a 1020. Com isso foi aplicado um threshold na imagem exportada em 16 bits gerando uma imagem binária (pixels entre a faixa de 1005 e 1020 recebem 0 e o restante recebe 1). Conforme Fig. 48.




Figura 48 - Threshold

- Closing – elemento estruturante 3




Figura 49 - Closing

- Segmentação (Mumford Shah)




Figura 50 - Mumford-Shah

- Bounding Box




Figura 51 - Bounding Box

Após a realização dessa sequência em todas as imagens tomográficas da série, as coordenadas do bounding box com as extremidades máximas do cérebro são calculadas.

3.1.1.8 AJUSTE AUTOMÁTICO DO ATLAS

Uma vez detectada a posição dos olhos e da base do quarto ventrículo, tanto horizontalmente quanto verticalmente, tem-se as coordenadas tanto verticalmente como horizontalmente do centro de massa de cada estrutura (olhos e base de quarto ventrículo).




Figura 52 – Visão tridimensional do cérebro

Com esses parâmetros o atlas pode ser ajustado em três visões: Axial (Fig. 53), Sagital (Fig. 54) e Coronal (Fig. 55).




Figura 53 – Visão Axial




Figura 54 – Visão Sagital




Figura 55 – Visão Coronal

Para o auto-ajuste na visão sagital basta calcular o ângulo vertical entre a base do quarto ventrículo e o centro dos olhos e verificar a diferença em relação ao ângulo predefinido no Plano Horizontal Alemão (14 graus aprox.).

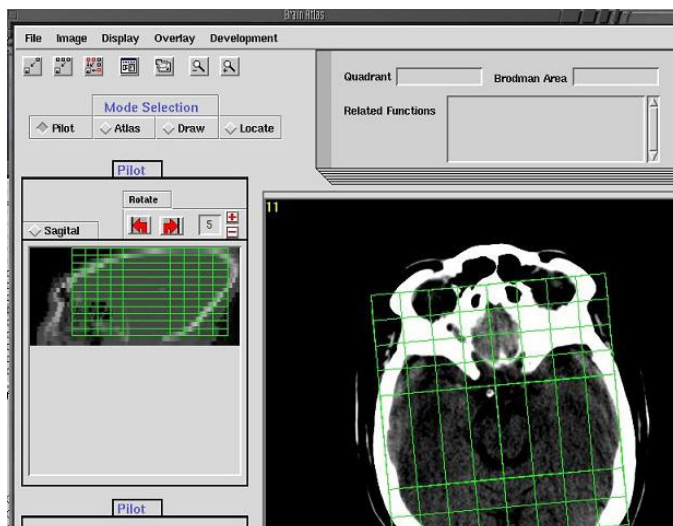


Figura 55 – Interface do sistema com auto-juste na visão sagital (esquerda) e na visão axial (direita)

Para o auto-ajuste da visão axial do atlas, uma vez tendo a reta entre a base do quarto ventrículo e o centro dos olhos, basta calcular a diferença angular entre essa reta e o bounding box gerado com as extremidades máximas do cérebro. Conforme demonstrado na Fig. 56.


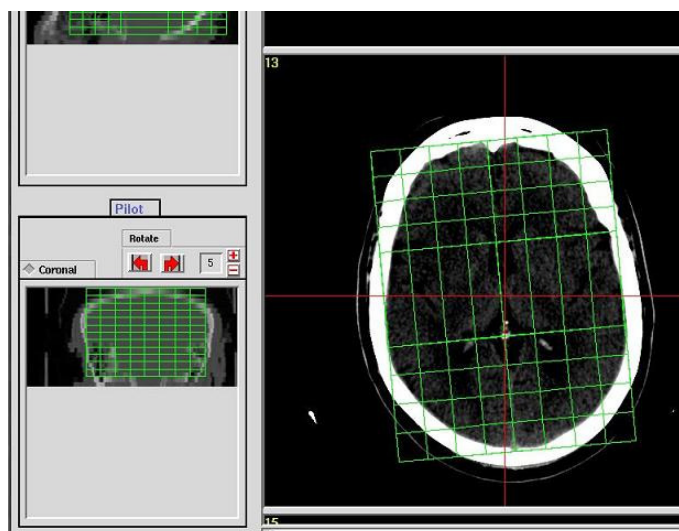


Figura 56 - Plano horizontal alemão

Para o auto-ajuste da visão coronal do atlas, uma vez tendo a reta entre o centro dos olhos, basta calcular a diferença angular entre essa reta e o bounding box gerado com as extremidades máximas do cérebro. Conforme demonstrado na Fig. 57



.Figura 57 - Interface do sistema com auto-juste na visão coronal (esquerda) e na visão axial (direita)

4 RESULTADOS E DISCUSSÃO

Em relação aos resultados obtidos com o sistema, observou-se que o sistema detectou adequadamente as estruturas e conseguiu adaptar o atlas cerebral automaticamente, sem interação de usuário. Esses testes foram feitos no Hospital Universitário em Florianópolis - SC em 200 séries completas de cérebro e foram apresentadas para 3 profissionais da área (médicos). A adaptação automatizada do atlas nas 200 séries de cabeça foi satisfatória alcançando um percentual de acerto de 95% e de acordo com os médicos, que avaliaram a ferramenta, a adaptação do atlas cerebral digital através da ferramenta foi realizada com maior precisão do que fosse feito manualmente por um médico.

Algumas dificuldades foram encontradas durante a validação, como exemplo, algumas séries tomográficas sem uma boa formação das estruturas base (olhos e quarto ventrículo) para o auto ajuste do atlas. Nessas séries o auto ajuste não funcionou adequadamente correspondendo à 3% das séries analisadas. Outra dificuldade foi a validação por parte dos médicos, pois a adaptação manual é imprecisa e um tanto subjetiva devido a dificuldade de identificação, a olho nu, das estruturas base para adaptação.

A ferramenta teve uma taxa de erro de 5%, sendo que 3% devido aos problemas de formação ou danos nas estruturas intracerebrais.

5 CONCLUSÃO

Com o desenvolvimento do sistema foram percebidas as dificuldades que existem na escolha de estratégias computacionais para a identificação e reconhecimento de objetos a partir de imagens de tomografia computadorizada. A interpretação dos dados resultantes dos exames radiológicos feita por um radiologista, apesar do vasto conhecimento e experiência na interpretação de imagens, para a adaptação de um atlas cerebral não é precisa devido a dificuldade em se encontrar referências visuais para o ajuste. E em decorrência disso a escolha da melhor metodologia foi bastante dificultada, principalmente pelo fato das imagens terem qualidades diferentes, com conteúdos bastante diferentes e necessitaram ser analisadas através do uso de complexos conhecimentos acerca dos elementos esperados.

Diante desse cenário foi possível realizar um estudo aprofundado de vários modelos de redes neurais, técnicas de computação gráfica e visão computacional para a correta classificação das estruturas.

Dessa forma foi desenvolvida uma metodologia que permite uma adaptação dinâmica e otimizada do processo de auto adaptação do atlas cerebral digital. A especificação dessa metodologia de identificação automatizada das estruturas que constituem o Plano Horizontal Alemão possibilita o auto-ajuste do Atlas Cerebral Digital e livra o médico do trabalho manual de adequação do sistema de coordenadas e permite o aumento da precisão referente às áreas cerebrais do paciente e ao posicionamento de possíveis lesões cerebrais.

Percebeu-se também que ainda existem muitas necessidades a serem sanadas em diversas áreas quando o assunto é software de auxílio ao diagnóstico médico, mesmo com grandes empresas desenvolvendo soluções nessa área. Dentre estas necessidades, uma ferramenta que auxilie o médico na localização de áreas cerebrais é uma delas. E ainda não existe uma ferramenta específica para prover esta solução de forma automatizada.

A continuação do desenvolvimento e aperfeiçoamento dessa metodologia se faz necessária e possível para fornecer uma solução de grande importância ao diagnóstico médico proporcionando ao profissional confiança e segurança.

6 REFERÊNCIAS BIBLIOGRÁFICAS

- [AFF98] AFFIF, Adel K.; BERGMAN, Ronald A. **Functional neuroanatomy**. Iowa: McGraw-Hill, 1998.
- [BAR97] BARRETO, J. M. **Inteligência Artificial no limiar do Século XXI**. Florianópolis, 1997, 1 ed.
- [CAR78] CARPENTER, Malcolm B. **Neuroanatomia Humana. Interamericana**. Rio de Janeiro, 1978.
- [CHU85] CHUSID, Joseph G. **Neuroanatomia Corretiva e Neuroanatomia Funcional**. Traduzido por Carlos Floriano de Maraes. Guanabara Koogan: Rio de Janeiro, 1985.
- [FAC93] FACON, Jacques. **Processamento e Análise de Imagens**. Córdoba : CEFET, 1993.
- [FAU94] FAUSETT, Laurene. *Fundamentals of Neural Networks*. New Jersey : Prentice Hall, 1994.
- [FOL96] FOLEY, James D; et al. **Computer graphics: principles and practice**. USA: Addison-Wesley Publishing Compny, inc, 1996.
- [HAR83] HARALICK, Robert M. **Pictorial Data Analysis**. Berlin : Springer, 1983.
- [HAR93] HARALICK, R.; SHAPIRO, L. **Computer and Robot Vision**. Addison Wesley, Vol. 2, 1993.
- [HAR90] HARRINGTON, Steven. **Computer graphics: a programming approach**. USA: McGraw Hill, 1990.
- [KRE93] KRETSCHMANN, Hans Joachim; WEINRICH, Wolfgang. **Neurofunctional systems: 3d reconstructions with correlated neuroimaging**. German: Ed. Thieme, 1996.

- [MAC93] MACHADO, Angelo B. M. **Neuroanatomia Funcional**. Belo Horizonte: Livraria Atheneu, 1993. 2ª edição.
- [MAR92] MAREN, Alianna J. ***Handbook of Neural Computing Applications***. San Diego : Academic Press, 1992.
- [MAR96] MARTINO, Marcello Baptista. **Redes Neurais**. 1996. Endereço eletrônico : [http:// www.cepel.br:80/~martino/rn.htm](http://www.cepel.br:80/~martino/rn.htm).
- [MUM89] MUMFORD, D.; SHAH J. **Optimal Approximations by Piecewise Smooth Functions and Associated Variational Problems**. Comm. Pure Appl. Math., 1989.
- [OSO91] OSÓRIO, Fernando Santos. **Um Estudo sobre Reconhecimento Visual de Caracteres através de Redes Neurais**. Porto Alegre : UFRGS, 1991.
- [OSO92] OSÓRIO, Fernandes M., **Introdução ao Reconhecimento de Imagens**. Porto Alegre : UFRGS, 1992.
- [PAR97] PARKER, James R. **Algorithms for image processing and computer vision**. New York: Wiley Computer Publishing, 1997.
- [PAZ88] PAZ, Eduardo Peixoto. **Iniciação ao Processamento Digital de Imagens**. Rio de Janeiro : UFRJ/NCE, 1988.
- [POR94] PORTO, Celmo Seleno. **Semiologia Médica**. Rio de Janeiro: Guanabara Koogam, 1994. 2ª edição.
- [ROB90] ROBERT, Hecht-Nielsen. **Neurocomputing**. Washington : Addison-Wesley Publishing Company, 1990.
- [TAL88] TALAIRACH, Jean; TOURNOUX, Pierre. **Co-Planar Stereotaxic Atlas of the Human Brain 3-dimensional Proportional System: an approach to cerebral imaging**. New York: Ed Thieme, 1988.

- [WAN93] WANG, Guyon. *Advances in Pattern Recognition Systems using Neural Network Technologies*. London : Word Scientific Publishing, 1993.
- [WAN97] v. WANGENHEIM, A.; BARRETO, J.M.; RICHTER, M.M.; KRECHEL, D.
Cyclops – Expert System Shell for the Development of Applications in the Area of Medical Image Analysis, in Jahnichen; Lucena(Eds):
Proceeding of the 4th German-Brazilian Workshop on Information Technology, Porto Alegre/Berlin,1997.